


UNIVERSIDADE FEDERAL DO PARANÁ

PAULO SERGIO DA CONCEIÇÃO MOREIRA



RECONHECIMENTO DE EMOÇÕES EM MÚSICAS POR MEIO DE SISTEMAS
NEURO-FUZZY

CURITIBA

2019

PAULO SERGIO DA CONCEIÇÃO MOREIRA

RECONHECIMENTO DE EMOÇÕES EM MÚSICAS POR MEIO DE SISTEMAS
NEURO-FUZZY

Dissertação apresentada ao Programa de Pós-Graduação em Gestão da Informação (PPGGI), Setor de Ciências Sociais Aplicadas da Universidade Federal do Paraná (UFPR), como requisito parcial à obtenção do título de Mestre em Gestão da Informação.

Orientadora: Profa. Dra. Denise Fukumi Tsunoda

CURITIBA
2019

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA DE CIÊNCIAS SOCIAIS
APLICADAS – SIBI/UFPR COM DADOS FORNECIDOS PELO(A) AUTOR(A)
Bibliotecário: Eduardo Silveira – CRB 9/1921

Moreira, Paulo Sergio da Conceição
Reconhecimento de emoções em músicas por meio de sistemas
Neuro-Fuzzy / Paulo Sergio da Conceição Moreira. - 2019.
176 p.

Dissertação (Mestrado) – Universidade Federal do Paraná.
Programa de Pós- Graduação em Ciência, Gestão e Tecnologia da
Informação, do Setor de Ciências Sociais Aplicadas.

Orientadora: Denise Fukumi Tsunoda.

Defesa: Curitiba, 2019.

1. Gestão da Informação. 2. Recuperação da Informação. 3. Música.
I. Universidade Federal do Paraná. Setor de Ciências Sociais Aplicadas.
Programa de Pós- Graduação em Ciência, Gestão e Tecnologia da
Informação. II. Tsunoda, Denise Fukumi. III. Título.

CDD 658.4038



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS SOCIAIS E APLICADAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO GESTÃO DA
INFORMAÇÃO - 40001016058P1

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em GESTÃO DA INFORMAÇÃO da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **PAULO SERGIO DA CONCEIÇÃO MOREIRA** intitulada: **RECONHECIMENTO DE EMOÇÕES EM MÚSICAS POR MEIO DE SISTEMAS NEURO-FUZZY**, sob orientação da Profa. Dra. DENISE FUKUMI TSUNODA, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua aprovação no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 25 de Outubro de 2019.

DENISE FUKUMI TSUNODA

Presidente da Banca Examinadora (UNIVERSIDADE FEDERAL DO PARANÁ)

JOSÉ SIMÃO DE PAULA PINTO

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

GLÁUCIA MARIA BRESSAN

Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ)

RESUMO

A partir da noção de que metadados tradicionais, como autoria artística e título da melodia, são insuficientes para a gestão das informações musicais, esta pesquisa objetiva reconhecer emoções em músicas por meio da aplicação de sistemas neuro-fuzzy. Caracterizada como pesquisa exploratória de abordagem quantitativa, analisa um corpus de 877 arquivos MP3 com trinta segundos de duração cada, coletados diretamente na plataforma *YouTube*, como representativos das emoções básicas “raiva”, “medo”, “felicidade”, “tristeza” e “surpresa”. Como método de classificação, aplica a estrutura *Adaptive Neuro-Fuzzy Inference System* (ANFIS) em quatro estratégias constituídas por conjuntos com cinco, quatro, três e duas emoções. Devido à complexidade computacional da estrutura ANFIS, elabora uma etapa de redução de atributos com o método de seleção de atributos *Correlation-based Feature Selection* (CFS), que resulta em conjuntos específicos para cada cenário proposto. Avalia promissores os resultados obtidos, principalmente os referentes às estratégias para três e duas emoções, cujas maiores taxas de acerto são 65,83% para as emoções “raiva”, “felicidade” e “tristeza”, e 88,75% para a classificação entre “raiva” e “tristeza”. Observa redução na taxa de acerto quando as emoções “medo” e “felicidade” compõem o mesmo conjunto, levantando a hipótese de que somente o conteúdo do áudio não seja o suficiente para a distinção das emoções. Verifica que, das emoções básicas, a associação entre música e a emoção “nojo” é de difícil compreensão. Com base nos resultados, identifica potencial na aplicação de sistemas neuro-fuzzy para problemas que apresentam incertezas e subjetividade.

Palavras-chave: Reconhecimento de emoções em músicas. Sistemas neuro-fuzzy. Gestão de informações musicais. Recuperação de informação musical.

ABSTRACT

Due to traditional metadata such as the artist names and song titles are insufficient for music information management, this research aims to music emotion recognition through the application of neuro-fuzzy systems. Characterized as exploratory research with a quantitative approach, it analyzes a corpus of 877 thirty-second MP3 files collected directly on the YouTube platform as representative of the basic emotions: anger, fear, happiness, sadness, and surprise. It applies the Adaptive Neuro-Fuzzy Inference System (ANFIS) structure as a classification method in four strategies consisting of sets with five, four, three, and two emotions. Owing to the computational complexity of the ANFIS structure, it elaborates an attribute reduction step with the Correlation-based Feature Selection (CFS) attribute selection method, which results in specific sets for each proposed scenario. The results obtained are promising, especially those concerning three and two emotions strategies, whose best results are 65.83% for the emotions anger, happiness, and sadness and 88.75% for the classification between anger and sadness. It observed a reduction in results when fear and happiness make up the same set, raising the possibility that only the audio content is not enough to distinguish emotions. It seems that the basic emotions, the relationship "music and disgust" emotion is hard to understand. Based on the results, it identifies potential in the application of neuro-fuzzy systems to problems that present uncertainties and subjectivity.

Keywords: Music information retrieval. Neuro-fuzzy systems.

Music emotion recognition. Music information management.

LISTA DE FIGURAS

FIGURA 1 - MODELO CIRCUMPLEXO DE AFETO PROPOSTO POR RUSSELL (1980).....	33
FIGURA 2 - MODELO TRIDIMENSIONAL DE EMOÇÕES PROPOSTO POR LÖVHEIM (2012).....	34
FIGURA 3 - MODELO TRIDIMENSIONAL DE EMOÇÕES PROPOSTO POR BAKKER ET AL. (2014).....	34
FIGURA 4 - CHECKLIST DE ADJETIVOS EMOCIONAIS PROPOSTO POR HEVNER (1936)	36
FIGURA 5 - CONJUNTOS FUZZY COM UNIVERSO DISCRETO E CONTÍNUO	43
FIGURA 6 - REPRESENTAÇÃO GRÁFICA DAS OPERAÇÕES BÁSICAS DE CONJUNTOS <i>FUZZY</i>	44
FIGURA 7 - FUNÇÃO DE PERTINÊNCIA TRIANGULAR.....	45
FIGURA 8 – FUNÇÃO DE PERTINÊNCIA TRAPEZOIDAL	46
FIGURA 9 - FUNÇÃO DE PERTINÊNCIA GAUSSIANA.....	47
FIGURA 10 - FUNÇÃO DE PERTINÊNCIA SINO.....	47
FIGURA 11 - ESTRUTURA ANFIS	55
FIGURA 12 - SÍNTESE DA CARACTERIZAÇÃO DA PESQUISA	59
FIGURA 13 - SÍNTESE DOS PROCEDIMENTOS PARA A CONSTRUÇÃO DA BASE DE DADOS	65
FIGURA 14 - INTERFACE GRÁFICA NEURO- <i>FUZZY DESIGNER</i>	66
FIGURA 15 - RESUMO DO PROCESSO DE SELEÇÃO DE ATRIBUTOS	72
FIGURA 16 - MATRIZ DE CONFUSÃO CINCO EMOÇÕES (TREINAMENTO)	74
FIGURA 17 - MATRIZ DE CONFUSÃO CINCO EMOÇÕES (TESTE).....	75
FIGURA 18 - MATRIZ DE CONFUSÃO QUATRO EMOÇÕES (TREINAMENTO).....	76
FIGURA 19 - MATRIZ DE CONFUSÃO QUATRO EMOÇÕES (TESTE).....	77
FIGURA 20 - MATRIZ DE CONFUSÃO (“RAIVA”; “MEDO” E “FELICIDADE” – TREINAMENTO)	79
FIGURA 21- MATRIZ DE CONFUSÃO (“RAIVA”; “MEDO” E “FELICIDADE” – TESTE).....	79

FIGURA 22 - MATRIZ DE CONFUSÃO (“RAIVA”; “MEDO” E “TRISTEZA” – TREINAMENTO)	80
FIGURA 23 - MATRIZ DE CONFUSÃO (“RAIVA”; “MEDO” E “TRISTEZA”	81
FIGURA 24 - MATRIZ DE CONFUSÃO (“RAIVA”; “FELICIDADE” E “TRISTEZA” – TREINAMENTO).....	82
FIGURA 25 - MATRIZ DE CONFUSÃO (“RAIVA”; “FELICIDADE” E “TRISTEZA” – TESTE)	83
FIGURA 26 - MATRIZ DE CONFUSÃO (“MEDO”; “FELICIDADE” E “TRISTEZA” – TREINAMENTO).....	84
FIGURA 27 - MATRIZ DE CONFUSÃO (“MEDO”; “FELICIDADE” E “TRISTEZA” – TESTE)	84
FIGURA 28 - MATRIZ DE CONFUSÃO (“RAIVA” E “MEDO” – TREINAMENTO)	86
FIGURA 29 - MATRIZ DE CONFUSÃO (“RAIVA” E “MEDO” – TESTE).....	86
FIGURA 30- MATRIZ DE CONFUSÃO (“RAIVA” E “FELICIDADE” – TREINAMENTO)	87
FIGURA 31 - MATRIZ DE CONFUSÃO (“RAIVA” E “FELICIDADE” – TESTE)	88
FIGURA 32 - MATRIZ DE CONFUSÃO (“RAIVA” E “TRISTEZA” – TREINAMENTO)	89
FIGURA 33 - MATRIZ DE CONFUSÃO (“RAIVA” E “TRISTEZA” – TESTE)	89
FIGURA 34 - MATRIZ DE CONFUSÃO (“MEDO” E “FELICIDADE” – TREINAMENTO)	90
FIGURA 35 - MATRIZ DE CONFUSÃO (“MEDO” E “FELICIDADE” – TESTE)	91
FIGURA 36 - MATRIZ DE CONFUSÃO (“MEDO” E “TRISTEZA” – TREINAMENTO)	91
FIGURA 37 - MATRIZ DE CONFUSÃO (“MEDO” E “TRISTEZA” – TESTE)	92
FIGURA 38 - MATRIZ DE CONFUSÃO (“FELICIDADE” E “TRISTEZA” – TREINAMENTO)	93
FIGURA 39 - MATRIZ DE CONFUSÃO (“FELICIDADE” E “TRISTEZA” – TESTE).....	93

LISTA DE QUADROS

QUADRO 1 -	LISTA DE EMOÇÕES BÁSICAS.....	31
QUADRO 2 -	ATUALIZAÇÃO DO <i>CHECKLIST</i> DE HEVNER (1936) POR SHUBERT (2003)	36
QUADRO 3 -	SÍNTESE DAS ESTRATÉGIAS ADOTADAS NO RECONHECIMENTO DE EMOÇÕES EM MÚSICAS.....	41
QUADRO 4 -	PROCEDIMENTOS DE COLETA E ANÁLISE DE DADOS.....	59
QUADRO 5 -	DEFINIÇÃO DAS “EMOÇÕES BÁSICAS” EMPREGADAS NESTE ESTUDO.....	61
QUADRO 6 -	INTERVALOS DEFINIDOS (CINCO EMOÇÕES)	68
QUADRO 7 -	INTERVALOS DEFINIDOS (QUATRO EMOÇÕES).....	68
QUADRO 8 -	INTERVALOS E CONJUNTOS (TRÊS EMOÇÕES	69
QUADRO 9 -	INTERVALOS E CONJUNTOS (DUAS EMOÇÕES).....	69
QUADRO 10 -	PARÂMETROS ADOTADOS PARA OS EXPERIMENTOS COM A ESTRUTURA ANFIS	70
QUADRO 11 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (CINCO EMOÇÕES).....	74
QUADRO 12 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (QUATRO EMOÇÕES)	76
QUADRO 13 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (RAIVA; MEDO E FELICIDADE)	78
QUADRO 14 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (RAIVA; MEDO E TRISTEZA).....	80
QUADRO 15 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (RAIVA; FELICIDADE E TRISTEZA)	82
QUADRO 16 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (MEDO; FELICIDADE E TRISTEZA).....	84
QUADRO 17 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (RAIVA E MEDO).....	85
QUADRO 18 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (RAIVA E FELICIDADE)	87
QUADRO 19 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (RAIVA E TRISTEZA).....	88
QUADRO 20 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (MEDO E FELICIDADE)	90
QUADRO 21 -	ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> (MEDO E TRISTEZA).....	91

QUADRO 22 - ESTRUTURA DO SISTEMA NEURO-*FUZZY* (FELICIDADE E TRISTEZA)92

QUADRO 23 - COMPARAÇÃO DOS RESULTADOS.....95

LISTA DE TABELAS

TABELA 1- QUANTIDADE DE REGISTROS PARA OS TERMOS "MUSIC EMOTION RECOGNITION"	21
TABELA 2- QUANTIDADE DE REGISTROS PARA OS TERMOS " <i>MUSIC EMOTION RECOGNITION</i> " AND " <i>FUZZY LOGIC</i> "	21
TABELA 3- QUANTIDADE DE REGISTROS PARA OS TERMOS " <i>MUSIC EMOTION RECOGNITION</i> " AND " <i>NEURO-FUZZY</i> "	22

LISTA DE SIGLAS

5-HT	5-HidroxiTryptamina
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
BDTD	Biblioteca Digital Brasileira de Teses e Dissertações
CFS	<i>Correlation-based Feature Selection</i>
CNN	<i>Convolutional Neural Network</i>
CoG	<i>Center of Gravity</i>
CTD	Catálogo de Teses e Dissertações da CAPES
DA	Dopamina
EEG	EletroEncefaloGrama
FoM	<i>First of Maxima</i>
KNN	<i>K-Nearest Neighbor</i>
LASSO	<i>Least Absolute Shrinkage and Selection Operator</i>
LoM	<i>Last of Maxima</i>
MER	<i>Music Emotion Recognition</i>
MFCCs	<i>Mel-Frequency Cepstral Coefficients</i>
MIR	<i>Music Information Retrieval</i>
MIREX	<i>Music Information Retrieval Evaluation eXchange</i>
MoM	<i>Middle of Maxima</i>
NE	Noradrenalina
NFNC	<i>Neuro-Fuzzy Networks Classification</i>
PDS	Processamento Digital de Sinais
RIM	Recuperação de Informação Musical
RMS	<i>Root Mean Square</i>
SC	<i>Spectral Centroid</i>
SF	<i>Spectral Flux</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
TKS	Takagi e Sugeno
ZCR	<i>Zero Crossing Rate</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	ABORDAGEM DO PROBLEMA	18
1.2	OBJETIVOS	20
1.2.1	Objetivo geral	20
1.2.2	Objetivos específicos	20
1.3	JUSTIFICATIVA	20
1.4	DELIMITAÇÃO DA PESQUISA	24
1.5	ESTRUTURA DO TRABALHO	24
2	REFERENCIAL TEÓRICO	26
2.1	RECUPERAÇÃO DE INFORMAÇÃO MUSICAL	26
2.2	EMOÇÕES	28
2.2.1	Emoções básicas	29
2.2.2	Abordagem dimensional das emoções	31
2.3	MÚSICA E EMOÇÃO	35
2.4	RECONHECIMENTO DE EMOÇÕES EM MÚSICAS	38
2.5	LÓGICA <i>FUZZY</i>	41
2.5.1	Conjuntos <i>fuzzy</i>	42
2.5.2	Funções de pertinência	44
2.5.3	Fuzzificação e Defuzzificação	48
2.5.4	Sistemas de inferência <i>fuzzy</i>	50
2.6	SISTEMAS NEURO- <i>FUZZY</i>	52
2.7	<i>ADAPTIVE NEURO FUZZY INFERENCE SYSTEM</i> (ANFIS)	54
3	ENCAMINHAMENTOS METODOLÓGICOS	58
3.1	CARACTERIZAÇÃO DA PESQUISA	58
3.2	COLETA E ANÁLISE DE DADOS	59
3.3	CRIAÇÃO DA BASE DE DADOS	60

3.4	EXPERIMENTOS UTILIZANDO A ESTRUTURA ANFIS	65
3.5	SELEÇÃO DE ATRIBUTOS	71
4	ANÁLISE E DISCUSSÃO DOS RESULTADOS.....	73
4.1	RESULTADOS OBTIDOS PARA CINCO E QUATRO EMOÇÕES	73
4.2	RESULTADOS ATINGIDOS PARA TRÊS EMOÇÕES	77
4.3	RESULTADOS ALCANÇADOS PARA DUAS EMOÇÕES.....	85
4.4	COMPARAÇÃO DOS RESULTADOS.....	93
5	CONSIDERAÇÕES FINAIS	97
	REFERÊNCIAS	100
	ANEXO A - MODELO PROPOSTO POR FONTAINE et al. (2007).....	123
	APÊNDICE A – ENDEREÇO DAS <i>PLAYLISTS</i> ELABORADAS	124
	APÊNDICE B – <i>SCRIPT</i> PARA <i>DOWNLOAD</i> DOS ARQUIVOS .MP3	125
	APÊNDICE C – <i>SCRIPT</i> PARA A EXTRAÇÃO DE DESCRITORES	126
	APÊNDICE D - ESTATÍSTICAS DESCRITIVAS DA BASE DE DADOS	129
	APÊNDICE E - CONJUNTOS DE ATRIBUTOS SELECIONADOS	130
	APÊNDICE F – TAXAS DE ACERTO E CENÁRIOS PARA CINCO EMOÇÕES	131
	APÊNDICE G - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA CINCO EMOÇÕES	133
	APÊNDICE H – TAXAS DE ACERTO E CENÁRIOS PARA QUATRO EMOÇÕES	135
	APÊNDICE I - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA QUATRO EMOÇÕES	136
	APÊNDICE J – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES (RAIVA; MEDO E FELICIDADE).....	139
	APÊNDICE K - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS EMOÇÕES (RAIVA; MEDO E FELICIDADE).....	140
	APÊNDICE L – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES (RAIVA; MEDO E TRISTEZA).....	143
	APÊNDICE M - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS EMOÇÕES (RAIVA; MEDO E TRISTEZA).....	145
	APÊNDICE N – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES	

(RAIVA; FELICIDADE E TRISTEZA)	146
APÊNDICE O - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS	
EMOÇÕES (RAIVA; FELICIDADE E TRISTEZA)	149
APÊNDICE P – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES	
(MEDO; FELICIDADE E TRISTEZA).....	151
APÊNDICE Q - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS	
EMOÇÕES (MEDO; FELICIDADE E TRISTEZA)	153
APÊNDICE R – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES	
(RAIVA E MEDO).....	155
APÊNDICE S - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS	
EMOÇÕES (RAIVA E MEDO)	156
APÊNDICE T – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES	
(RAIVA E FELICIDADE)	159
APÊNDICE U - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS	
EMOÇÕES (RAIVA E FELICIDADE).....	160
APÊNDICE V – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES	
(RAIVA E TRISTEZA).....	163
APÊNDICE W - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS	
EMOÇÕES (RAIVA E TRISTEZA).....	165
APÊNDICE Y - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS	
EMOÇÕES (MEDO E FELICIDADE)	168
APÊNDICE Z – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES	
(MEDO E TRISTEZA)	171
APÊNDICE AA - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS	
EMOÇÕES (MEDO E TRISTEZA)	173
APÊNDICE BB – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES	
(FELICIDADE E TRISTEZA).....	175
APÊNDICE CC - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS	
EMOÇÕES (FELICIDADE E TRISTEZA).....	176

1 INTRODUÇÃO

A música é um elemento importante da vida humana e está presente em momentos distintos da vida cotidiana, atendendo a propósitos sociais e individuais e sendo utilizada em campos diversos como a religião, os esportes, o entretenimento e até mesmo na guerra (PANDA; ROCHA; PAIVA, 2015). Trata-se de um elemento de comunicação que possibilita ao ser humano transmitir suas emoções, expressar sua filosofia de vida ou manifestar suas posições políticas (NIKOLAOU, 2011; PANDA; PAIVA, 2011).

Dentro da gama de situações em que a música é objeto de estudo, a relação entre música e emoção fascina o ser humano desde a antiguidade (LAURIER, 2011), pois a mesma esteve presente desde o começo da humanidade, por meio da transmissão de emoções e percepções ao ouvinte, além do que, seus elementos alteram-se conforme a variação da percepção que cada cultura atribui à música ao longo dos anos (NIKOLAOU, 2011; PANDA; ROCHA; PAIVA, 2015) e, além disso, à medida que o ser humano amadurece psicologicamente, fatores biológicos e neurológicos também podem interferir na relação música-emoção (NIKOLAOU, 2011).

A música pode encorajar e animar as atividades realizadas pelo ser humano e, em uma civilização moderna, cheia de pressão e estresse, surge como uma fonte de relaxamento que pode gerenciar e reduzir o estresse e a ansiedade (MOHAMMADPOUR et al., 2017) uma vez que, é um elemento capaz de despertar diversos tipos de emoções (CHEN et al., 2015).

Por estes motivos, a música tornou-se objeto de estudo da neurociência nos últimos anos e os resultados indicam que esta pode melhorar funções do cérebro, como a memória, a emoção, a atenção, a aprendizagem e a neuroplasticidade (MOHAMMADPOUR et al., 2017).

Na era da internet a música está em todo lugar devido às inovações tecnológicas e a fatores como o acesso generalizado à internet e o uso massivo do mp3 (PANDA; ROCHA; PAIVA, 2015). Somado a estes fatores, as plataformas de *streaming* como Deezer® e Spotify® forneceram, por meio de planos gratuitos e pagos, o acesso a uma grande coleção de músicas via internet, seja para consumo em computadores ou por dispositivo móvel (LIIKKANEN; ÅMAN, 2015).

Neste contexto, à medida que o volume de músicas aumenta, as abordagens convencionais de gerenciamento musical por meio de metadados como o nome do

artista e/ou o título da música, não são suficientes e isso exige esforços da comunidade de recuperação de informações musicais (*music information retrieval* (MIR)) para que novos elementos sejam adotados (YANG; CHEN, 2012), bem como novas formas de organização e recuperação para atender à crescente demanda por parte dos usuários (YANG; CHEN, 2012; PANDA; ROCHA; PAIVA, 2015).

Dentre as possibilidades de gerenciamento e recuperação, o reconhecimento de emoções em músicas (*Music Emotion Recognition* (MER)) surge como um campo de pesquisa promissor e que se desenvolveu na última década (HSIAO; CHEN; LEE, 2017; ALJANAKI; YANG; SOLEYMANI, 2017) em decorrência do interesse da indústria musical em melhorar os métodos automáticos de categorização musical para o volume de música disponível atualmente (ALJANAKI; YANG; SOLEYMANI, 2017).

O interesse nos estudos desenvolvidos com o objetivo de reconhecer emoções em músicas aumentou a partir de 2007 quando a *Music Information Retrieval Evaluation eXchange* (MIREX) acrescentou a temática como uma das tarefas para pesquisadores submeterem suas pesquisas (KIM et al., 2010). Estudos com esta temática recebem cada vez mais atenção de pesquisadores em razão da possibilidade de empregar os resultados em diferentes atividades que vão além de aplicações para recomendação de músicas e criação de *playlists* automáticas, envolvendo desde o desenvolvimento de jogos e trilhas de cinema a campanhas publicitárias (MALHEIRO, 2016).

Outro ponto importante que corrobora para este crescimento consiste no fato de que uma das razões pelas quais as pessoas acham uma música agradável é o seu impacto emocional (ALJANAKI; WIERING; VELTKAMP, 2016). Entretanto, a percepção emocional é intrinsecamente subjetiva, e as pessoas podem perceber emoções diferentes ao longo de uma mesma música (YANG et al., 2008; NIKOLAOU, 2011; MALHEIRO, 2016), pois, a emoção, muitas vezes, pode estar ligada a diversos fatores como memórias, experiências, cultura, idade, gênero e personalidade (MALHEIRO, 2016).

Além de toda a natureza ambígua e subjetiva das emoções, a própria música é um objeto cuja definição não encontra um consenso. Prova disso são as diferentes definições propostas por profissionais das mais diversas áreas como lexicógrafos, linguistas, sociólogos e neurologistas (NIKOLAOU, 2011).

Diante deste contexto introdutório quanto ao tema, este estudo visa o reconhecimento de emoções em músicas por meio da aplicação dos conceitos

relacionados aos sistemas neuro-*fuzzy*. Sendo assim, a seguir apresenta-se a abordagem do problema, em que se elencam as características que condicionam a definição da questão norteadora de pesquisa e, na sequência, define-se os objetivos - geral e específicos – e a justificativa para a construção desta pesquisa.

1.1 ABORDAGEM DO PROBLEMA

Apesar do aumento das pesquisas realizadas nos últimos anos, o reconhecimento automático de emoções em músicas continua sendo um desafio (HUQ; BELLO; ROWE, 2010; WANG; WANG; LANCKRIET, 2015) e apresenta-se como uma questão de pesquisa promissora e importante no campo da recuperação de informações musicais (HSU et al., 2017).

Ao longo dos anos, pesquisadores de diferentes áreas têm utilizado uma infinidade de tópicos de pesquisa que englobam desde a psicoacústica, o Processamento Digital de Sinais (PDS) e a Ciência da Computação, contudo, ainda há questões no reconhecimento de emoções em músicas que não permitem o completo entendimento de como a música induz à emoção (ZHANG et al., 2016).

Visando encontrar respostas para este desafio, a maioria dos estudos relacionados ao reconhecimento de emoções utiliza duas abordagens: modelos categóricos e dimensionais da emoção (SONG; DIXON; PEARCE, 2012). A abordagem categórica descreve as emoções com um número limitado de categorias inatas e universais, em que se aplica um algoritmo de aprendizagem de máquina para classificar as emoções (CHIANG; WANG; HSU, 2014).

Por sua vez, a abordagem dimensional leva em consideração a posição das características da música representando-as em um sistema de coordenadas com os eixos denominados valência (negativa - positiva) e excitação (calma - excitante) (SONG; DIXON; PEARCE, 2012; CHIANG; WANG; HSU, 2014).

Normalmente, o reconhecimento de emoções em músicas consiste em um problema de aprendizado de máquina que identifica os padrões entre as características musicais e as emoções (WANG; WANG; LANCKRIET, 2015). Este procedimento faz uso de algoritmos de classificação, oriundos da Ciência da Computação que visam a aplicação de métodos de aprendizado estatístico, aprendizado de máquina e mineração de dados para modelar, aprender e entender a relação entre os dados – músicas - e a emoção (ZHANG et al., 2016).

Entretanto, devido à subjetividade da percepção humana, a estratégia de atribuir uma música a uma classe de emoção de forma determinística não é mais adequada, dado que, nem todas as pessoas compartilham o mesmo sentimento por uma música (YANG; LIU; CHEN, 2006) e a noção de emoção, bem como dos seus elementos estruturais, é confusa e incerta (KARYOTIS et al., 2018).

A subjetividade dificulta a avaliação do desempenho de um sistema de MER porque é difícil obter um acordo comum quanto ao resultado obtido, uma vez que, não é fácil descrever a emoção de maneira universal, por conta dos diferentes – às vezes ambíguos - adjetivos usados para descrever as emoções e que podem variar de pessoa para pessoa, bem como ainda é inexplicável como a música evoca emoções e qual elemento da música, se houver, cria uma resposta emocional específica no ouvinte (YANG et al., 2008).

Uma possível abordagem para contornar este aspecto subjetivo das emoções consiste no uso da lógica *fuzzy* nas estratégias de reconhecimento de emoções (BARTHET; FAZEKAS; SANDLER, 2012), pois, ao contrário das estratégias que associam determinadas músicas a um conjunto único ou discreto de emoções, o uso da lógica *fuzzy* permite representar a pertinência de uma música à cada categoria de emoção em um determinado modelo (BARTHET; FAZEKAS; SANDLER, 2012; YANG; DONG; LI, 2017).

A forma como a emoção de uma música é trabalhada na lógica *fuzzy* pode efetivamente aliviar o impacto da subjetividade humana no que tange às emoções (YANG; DONG; LI, 2017). No entanto, mesmo apresentando-se como uma solução mais adequada do que a abordagem determinística, ainda não pode evitar a ambiguidade das categorias de emoção (YANG; DONG; LI, 2017).

Além do mais, a lógica *fuzzy* tem a "desvantagem" de não apresentar uma capacidade de aprendizagem (MITRA; HAYASHI, 2000; CERVANTES et al., 2017). Neste sentido, para contornar esta “desvantagem” e trabalhar com incerteza e subjetividade, uma possível abordagem consiste no uso de sistemas *neuro-fuzzy*, tendo em vista aplicações em trabalhos de reconhecimento de emoções em imagens (WANG et al., 2018), fala (MOTAMED; SETAYESHI; RABIEE, 2017) e músicas (BAI et al., 2017).

Deste modo, esta pesquisa apresenta a seguinte questão norteadora: **como aplicar os conceitos relacionados aos sistemas *neuro-fuzzy* no reconhecimento de emoções em músicas?**

1.2 OBJETIVOS

Para responder ao problema de pesquisa, definiu-se os objetivos a serem alcançados com a pesquisa, sendo um objetivo geral e três objetivos específicos.

1.2.1 Objetivo geral

Reconhecer emoções em músicas por meio da aplicação de sistemas neuro-*fuzzy*.

1.2.2 Objetivos específicos

O objetivo geral deste estudo desdobra-se nos seguintes objetivos específicos:

- a) definir a taxonomia de emoções a ser utilizada;
- b) construir uma base de dados composta por um conjunto de descritores;
- c) comparar os resultados obtidos frente aos obtidos com outros métodos de classificação.

1.3 JUSTIFICATIVA

Como forma de encontrar trabalhos já realizados com a temática proposta, realizou-se um levantamento preliminar no dia 19 de abril de 2019 em quatro bases de dados científicas frequentemente utilizadas pela comunidade acadêmica e cujo acesso é fornecido pela Universidade Federal do Paraná (UFPR). A primeira estratégia de busca consistiu no uso da expressão “*music emotion recognition*”. O resultado desta estratégia é listado na Tabela 1.

TABELA 1- QUANTIDADE DE REGISTROS PARA OS TERMOS "*MUSIC EMOTION RECOGNITION*"

BASE	TERMO DE BUSCA	QUANTIDADE DE REGISTROS
Web of Science	<i>"music emotion recognition"</i>	106
IEEE Xplore	<i>"music emotion recognition"</i>	80
Scopus	<i>"music emotion recognition"</i>	176
ScienceDirect	<i>"music emotion recognition"</i>	32
TOTAL		394

FONTE: Elaborado pelo Autor (2019).

O total de registros encontrados corresponde a 394 trabalhos, contudo, ao remover os registros presentes em mais de uma base, o total de registros para a expressão "*music emotion recognition*" caiu para 217 trabalhos.

Ao refinar a estratégia de busca a fim de obter resultados mais adequados à presente proposta, realizou-se uma busca com a expressão "*music emotion recognition*" and "*fuzzy logic*". Os resultados estão listados na Tabela 2.

TABELA 2- QUANTIDADE DE REGISTROS PARA OS TERMOS "*MUSIC EMOTION RECOGNITION*" AND "*FUZZY LOGIC*"

BASE	TERMO DE BUSCA	QUANTIDADE DE REGISTROS
Web of Science	<i>"music emotion recognition" and "fuzzy logic"</i>	2
IEEE Xplore	<i>"music emotion recognition" and "fuzzy logic"</i>	2
Scopus	<i>"music emotion recognition" and "fuzzy logic"</i>	1
ScienceDirect	<i>"music emotion recognition" and fuzzy logic"</i>	0
TOTAL		5

FONTE: Elaborado pelo Autor (2019).

Ao analisar-se os resultados, verificou-se que um dos registros estava duplicado, desta forma, o total de registros para a expressão "*music emotion recognition*" and "*fuzzy logic*" corresponde a quatro trabalhos.

O primeiro trabalho recuperado consiste no desenvolvimento de um sistema de reconhecimento de emoções baseado em lógica *fuzzy* cujo foco não consiste em reconhecer as emoções musicais, mas sim, em identificar os graus de valência e excitação das músicas.

O estudo, apesar de empregar os conceitos da lógica *fuzzy*, caracteriza-se por apresentar uma estratégia semelhante à estratégia determinística, posto que, o resultado final consiste em determinar qual a posição de uma determinada música - com base nos respectivos graus de valência e excitação - em um espaço bidimensional desenvolvido pelos autores (JUN et al., 2008).

No segundo registro analisado, o objetivo dos autores – apesar de baseado na lógica *fuzzy* - consistiu em experimentos destinados apenas ao reconhecimento de emoções em músicas tradicionais da China, mais precisamente músicas desenvolvidas por um instrumento denominado “*Chime Bell*” (LIU; SUN; PAN, 2004).

O terceiro trabalho recuperado teve como objetivo a construção de um novo classificador *fuzzy* para o reconhecimento de emoções em músicas baseado no método gradiente descendente (ZHU; ZHAO; TANG, 2010).

Por fim, o quarto trabalho recuperado consiste em um experimento para validar um modelo *fuzzy* com nove estados emocionais (HUANG et al., 2018). Nesta abordagem, os autores realizaram uma comparação dos resultados frente aos resultados obtidos após a análise de um questionário preenchido por voluntários, em que estes, após a audição de trechos musicais, apontavam qual dos estados emocionais perceberam (HUANG et al., 2018).

No tocante à combinação “*music emotion recognition*” and “*neuro-fuzzy*”, ao realizar-se a busca por esta estratégia, obteve-se o seguinte resultado disposto na Tabela 3.

TABELA 3- QUANTIDADE DE REGISTROS PARA OS TERMOS “*MUSIC EMOTION RECOGNITION*” AND “*NEURO-FUZZY*”

BASE	TERMO DE BUSCA	QUANTIDADE DE REGISTROS
Web of Science	“ <i>music emotion recognition</i> ” and “ <i>neuro-fuzzy</i> ”	2
IEEE Xplore	“ <i>music emotion recognition</i> ” and “ <i>neuro-fuzzy</i> ”	1
Scopus	“ <i>music emotion recognition</i> ” and “ <i>neuro-fuzzy</i> ”	2
ScienceDirect	“ <i>music emotion recognition</i> ” and “ <i>neuro-fuzzy</i> ”	1
TOTAL		6

FONTE: Elaborado pelo Autor (2019).

Ao analisar-se os resultados, verificou-se que apenas dois registros eram únicos e que o trabalho desenvolvido por Zhang, Tjondronegoro e Chandran (2014) não apresentava conceitos e estratégias relacionados ao reconhecimento de emoções em músicas e à *neuro-fuzzy*.

Analisando o trabalho restante, verificou-se tratar de um experimento comparativo entre várias estratégias de classificação, dentre as quais, há a aplicação de uma estratégia *neuro-fuzzy* denominada como *Neuro-Fuzzy Networks Classification* (NFNC). Contudo, apesar do emprego desta estratégia, esta não era o foco dos autores, haja visto que o objetivo era a comparação de diversos algoritmos

como forma de obter o melhor desempenho em termos de classificação (BAI et al., 2017).

Mediante a necessidade de identificar teses e dissertações já desenvolvidas com temática semelhante à proposta neste trabalho, realizou-se uma busca preliminar no dia 20 de abril de 2019 em dois repositórios nacionais - Biblioteca Digital Brasileira de Teses e Dissertações (BDTD) e o Catálogo de Teses e Dissertações da CAPES (CTD) pela expressão “*music emotion recognition*”.

O resultado desta estratégia retornou apenas uma dissertação para ambos os repositórios. A dissertação em questão consistiu em um experimento de classificação automática de emoções em músicas latinas. A estratégia de classificação adotada pelo autor baseou-se na combinação de três fontes de informações (cifras, áudio e letras) extraídas de um total de 784 músicas. Como algoritmos, o autor empregou os seguintes classificadores: *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN) e J48.

Desta forma, percebe-se que não houve nenhuma estratégia relacionada à lógica *fuzzy*, tampouco à *neuro-fuzzy* na dissertação recuperada. Por sua vez, não houve registros recuperados nestes repositórios para as buscas com as estratégias “*music emotion recognition*” and “*fuzzy logic*” e “*music emotion recognition*” and “*neuro-fuzzy*”.

Posto o resultado dos levantamentos realizados, observa-se que o tema proposto se apresenta como um tema pouco explorado, tendo sua produção relacionada basicamente à Ciência da Computação. Entretanto, caracteriza-se como uma pesquisa de natureza interdisciplinar, formada por conhecimentos oriundos de diferentes conhecimentos, como a Ciência da Informação (recuperação de informação), a Engenharia (processamento de sinais digitais), a Psicologia (definições e modelos de emoções) e a Música.

Por conta desta natureza interdisciplinar, verifica-se que a presente proposta se alinha com os objetivos do Programa de Pós-Graduação em Gestão da Informação (PPGGI) e com a linha de pesquisa escolhida - Informação, tecnologia e gestão - e, além disso, mesmo com mais de 100 dissertações já elaboradas no âmbito do PPGGI, consiste em uma temática inédita.

No que tange à questão social, mesmo não sendo o objetivo proposto, os resultados obtidos e a metodologia desenvolvida neste estudo podem contribuir para que novas pesquisas e ações sejam desenvolvidas por áreas como a Musicoterapia

(MÖSSLER et al., 2017) e por profissionais desta e de outras áreas que utilizam a música - bem como as emoções provocadas por esta - como instrumento no tratamento e no estudo de distúrbios como a esquizofrenia (WEISGERBER et al., 2015; ABE; ARAI; ITOKAWA, 2017), o câncer (BRADT et al., 2014) e o autismo (DE VRIES et al., 2015; MÖSSLER et al., 2017).

1.4 DELIMITAÇÃO DA PESQUISA

Esta pesquisa não tem por objetivo analisar outros possíveis elementos presentes na relação “música-emoção”, como, por exemplo: a) conteúdo léxico-semântico presente em letras; b) progressões de acordes; e c) elementos socioculturais e históricos. Desta forma, limita-se apenas na análise de descritores obtidos a partir de análises relacionadas ao sinal de áudio das músicas.

Tendo em vista a natureza interdisciplinar do Programa de Pós-Graduação em Gestão da Informação e os conteúdos neste abordado, o presente estudo não visa exaurir todos os modelos e conceitos de emoções discutidos na Psicologia, tampouco almeja o aprofundamento matemático existente na área da Engenharia.

1.5 ESTRUTURA DO TRABALHO

A primeira seção corresponde à introdução da pesquisa. Nesta seção estão apresentados a contextualização do tema, o problema de pesquisa, o objetivo geral e os objetivos específicos e, por fim, a justificativa para a realização deste trabalho.

Na segunda seção apresenta-se o referencial teórico parcial. Aborda-se os seguintes conceitos: recuperação de informação musical; emoções, música e emoção; reconhecimento de emoções em músicas; lógica *fuzzy*; sistemas *neuro-fuzzy* e os conceitos da estrutura *Adaptive Neuro Fuzzy Inference System* (ANFIS).

A terceira seção é destinada aos encaminhamentos metodológicos da pesquisa. Nesta seção caracteriza-se a presente pesquisa, bem como apresenta-se as estratégias relacionadas à coleta e à análise dos dados. Nesta seção, apresenta-se os procedimentos adotados para a criação da base de dados deste estudo; a etapa de seleção de atributos e os procedimentos empregados para a realização dos experimentos relacionados à construção dos sistemas *neuro-fuzzy*.

A quarta seção apresenta os resultados obtidos do estudo e a comparação destes. Por fim, a quinta seção contempla as considerações finais deste estudo, bem como as sugestões para a continuidade do mesmo.

2 REFERENCIAL TEÓRICO

Nesta seção são explorados os principais conceitos relacionados ao tema e à problemática desta dissertação. Apresentam-se os seguintes conceitos: recuperação de informação musical; emoções; música e emoção; reconhecimento de emoções em músicas; lógica *fuzzy*; sistemas *neuro-fuzzy* e os conceitos da estrutura *Adaptive Neuro Fuzzy Inference System* (ANFIS).

2.1 RECUPERAÇÃO DE INFORMAÇÃO MUSICAL

A área conhecida como recuperação de informação musical (RIM) - do inglês *Music Information Retrieval* (MIR) - surgiu em um cenário marcado pela grande quantidade de música digital disponível, provocada pelo aumento de consumidores e pelo desenvolvimento de novas tecnologias relacionadas ao consumo de música (ORIO, 2006; LIEM, 2015; GURJAR; MOON, 2018). A recuperação de informação musical caracteriza-se como uma área multidisciplinar, sustentada por conhecimentos de áreas como a biblioteconomia, a ciência da informação, a musicologia, a teoria musical, a engenharia de áudio, a ciência da computação e o direito (DOWNIE, 2005).

As pesquisas oriundas da RIM visam garantir o acesso e o consumo melhorados e aprimorados das informações em um cenário em que a música é cada vez mais disseminada de forma digital (LIEM, 2015; SCHEDL, 2017). Desta forma, pesquisadores da área da RIM criaram estratégias automatizadas de processamento de dados musicais adequadas a uma sociedade em que há um excesso de conteúdo gerado por usuários (LIEM, 2015; SCHEDL, 2017).

As estratégias desenvolvidas destinaram-se, principalmente, à extração de características significativas de músicas, à indexação de músicas a partir destas características e ao desenvolvimento de novas abordagens de busca e recuperação, tais como a criação de sistemas de recomendação musical (SCHEDL; GÓMEZ; URBANO, 2014) com suporte à navegação, descoberta, compartilhamento e formação de comunidades de usuários (KAMINSKAS; RICCI, 2012).

De acordo com Casey et al. (2008), os resultados proporcionados pela RIM beneficiam os órgãos da indústria musical, responsáveis pelo registro e divulgação de músicas; os consumidores em busca de conteúdo personalizado; e os profissionais como músicos, professores, musicólogos, advogados de direitos autorais e produtores

de musicais. Em relação aos consumidores, especialmente, a ideia básica consiste em recuperar e sugerir músicas dependendo da situação real destes como, por exemplo, levando em consideração o seu estado emocional ou quaisquer outras condições contextuais que possam influenciar na sua percepção musical (KAMINSKAS; RICCI, 2012).

Em geral, as estratégias utilizadas consistem na análise do sinal do áudio por meio da extração de descritores como os obtidos no domínio do tempo, como *Root Mean Square* (RMS) e *zero crossing rate* (ZCR) e aqueles obtidos no domínio da frequência, como os descritores espectrais *Spectral Flux* (SF), *Spectral Centroid* (SC) e *Spectral Roll-Off* (MURTHY; KOOLAGUDI, 2018). Em seguida, estes descritores são submetidos a algoritmos de aprendizagem de máquina supervisionados como KNN, SVM ou redes neurais (SIEDENBURG; FUJINAGA; MCADAMS, 2016).

Dentre as tarefas mais exploradas no campo da recuperação de informação musical, destacam-se o reconhecimento de artistas, a classificação de gêneros musicais (rock, pop, hip-hop, folk, música clássica); o reconhecimento de emoções e a classificação de instrumentos musicais (instrumentos de percussão, de corda ou teclado, por exemplo) (MURTHY; KOOLAGUDI, 2018).

No que tange ao reconhecimento automático de artistas, a voz é o principal elemento analisado por ser o mais antigo dos instrumentos musicais e, além disso, devido às qualidades vocais de um determinado cantor, é possível reconhecer que uma determinada música pertence a um artista ou conjunto específico até mesmo em uma primeira audição (KIM; WHITMAN, 2002).

Por meio da voz (canto) é possível reconhecer um artista sem utilizar nenhum metadado relacionado à música, permitindo aos usuários descobrirem músicas com vozes semelhantes àquela que mais lhe agrada (FUJIHARA et al., 2010) por meio de estratégias como a separação do som vocal e a extração de recursos de fala (SU; YANG, 2013).

Com relação à classificação de instrumentos musicais, apesar do ser humano ser capaz de reconhecer com certa facilidade quais os tipos utilizados em uma determinada música, a análise automática realizada por computadores é uma tarefa difícil devido às variações de timbre e estilo de tocar de cada músico (HAN; KIM; LEE, 2017). Entretanto, a classificação automática é útil na transcrição e na indexação automáticas de músicas e na classificação do gênero musical, além de auxiliar na

procura de músicas executadas por um mesmo conjunto de instrumentos específicos (EGGINK; BROWN, 2004; HAN; KIM; LEE, 2017).

Quanto à classificação de gênero musical, esta consiste em uma das estratégias mais comuns adotadas para o gerenciamento de música digital, sendo uma tarefa importante da área de RIM desde 2002 (NANI et al., 2016). Gêneros musicais, por serem rótulos criados por seres humanos, por meio de uma interação complexa de culturas e por apresentarem características em comum entre eles, a classificação automática destes fornece uma estrutura para desenvolver e avaliar recursos para qualquer tipo de análise baseada em conteúdo de sinais musicais (TZANETAKIS; COOK, 2002; DEFFERRARD et al., 2018).

2.2 EMOÇÕES

Emoções são um dos aspectos mais centrais e profundos da experiência humana (ORTONY; CLORE; COLLINS, 1990). Presume-se que as emoções sejam elementos básicos, ou seja, elementos primitivos do ponto de vista biológico e psicológico (BARRETT, 2013). O estudo das emoções já era fruto de pesquisa desde os trabalhos desenvolvidos por Charles Darwin (LÖVHEIM, 2012; BARRETT, 2013; EKMAN, 2016) e que deram origem ao seu livro *"The expression of the emotions in man and animals"* (DARWIN, 1998).

De forma simples, as emoções são reações biorregulatórias responsáveis por promover, direta ou indiretamente, estados fisiológicos que asseguram não apenas a sobrevivência, mas a sobrevivência regulada no âmbito do que é conhecido como bem-estar (DAMASIO, 2004). Outra definição acerca das emoções consiste em compreendê-las como respostas afetivas automáticas e discretas a eventos universalmente compartilhados, específicos da cultura e específicos do indivíduo e que, apesar de pré-programadas e involuntárias, são moldadas pelas experiências de vida (EKMAN; CORDARO, 2011).

De um ponto de vista psicológico da emoção, pressupõe-se que as emoções sejam eventos oriundos de operações psicológicas mais básicas, emergindo a partir de informações sensoriais do corpo (LINDQUIST et al., 2012) manifestando-se como uma mudança temporária no estado de afeto ou sentimento, provocada por uma situação afetivamente importante (HAMANN, 2012). Em termos de um conceito preciso e definitivo, entretanto, há pouca concordância quanto a uma resposta

(CABANAC, 2002; RUSSEL, 2003; HAMANN, 2012), posto que, não há critérios suficientes para determinar o que é ou não uma emoção (RUSSEL, 2003) e, na maior parte do tempo, tende-se a representar a emoção como uma lista de palavras como raiva, alegria e tristeza ou, ainda, por meio de rótulos como feliz, triste e amedrontado (PLUTCHIK, 1980; CABANAC, 2002).

Além da falta de critérios, as emoções tendem a afetar as pessoas de diferentes formas, uma vez que a mesma emoção pode provocar efeitos diferentes em pessoas diferentes e, até mesmo, efeitos diferentes sobre a mesma pessoa em situações distintas (IZARD, 2013). Deste modo, acredita-se que a emoção não é apenas uma experiência subjetiva em si, mas sim um construto teórico complexo cujas características só podem ser inferidas com base em um conjunto de várias classes de evidências e nenhum índice único de emoções é livre de algum viés (PLUTCHIK, 1980; EKMAN, 1992).

Apesar da falta de consenso quanto a um conceito definitivo, um ponto em comum do debate no estudo das emoções consiste em qual seria a melhor maneira de representá-las. Duas correntes teóricas se consolidaram com o passar dos anos: a primeira, defendendo que as emoções são elementos básicos e irredutíveis da vida emocional, representadas por um número finito de termos como medo, raiva e nojo; a segunda, adotando uma abordagem dimensional em que as emoções devem ser compreendidas levando-se em consideração aspectos como a excitação e a valência (BARRETT; WAGER, 2006; HINOJOSA et al., 2016; HARMON-JONES; HARMON-JONES; SUMMERELL, 2017).

A seguir apresenta-se uma discussão acerca destas abordagens.

2.2.1 Emoções básicas

Assim como há diferenças quanto ao conceito geral de emoções, no que tange às emoções denominadas como básicas o cenário se repete. Contudo, no que diz respeito à existência de um número pequeno de emoções primárias, geralmente assume-se que este grupo é composto por emoções como o medo, a raiva, a alegria, a tristeza, a surpresa e o nojo (HAMANN, 2012; CELEGHIN et al., 2017), sendo um subconjunto de emoções discretas consideradas mais elementares e adaptativas e culturalmente universais (HAMANN, 2012).

As emoções básicas caracterizam-se como uma classe especial de emoções discretas, intimamente relacionadas às funções críticas de sobrevivência (LEVENSON, 2011). Cada emoção apresenta características únicas como fisiologia, sinais e eventos antecedentes, além de características em comum com outras emoções, que envolvem intervalos de duração e a espontaneidade, por exemplo, diferenciando-as de outros fenômenos afetivos e transformando-as em um produto da evolução humana (EKMAN, 1992).

A perspectiva das emoções básicas é o contraste de perspectivas que entendem as emoções como fundamentalmente semelhantes em determinados aspectos, diferenciando-se apenas em termos de uma ou mais dimensões, como a excitação e o prazer; ou, ainda, aquelas que consideram emoções apenas como algo positivo ou negativo (EKMAN, 1992).

Este tipo de emoção está presente em animais inferiores - assim como nos humanos - de modo que as emoções são vistas em um amplo contexto evolucionário (EKMAN, 1992), reforçando a hipótese de que certas categorias de emoções são biologicamente/psicologicamente primitivas (TRACY; RANDLES, 2011; CLARK-POLNER; JOHNSON; BARRETT, 2016), sendo a evidência mais forte para distingui-las proveniente da pesquisa sobre expressões faciais (EKMAN, 1992; POSNER; RUSSELL; PETERSON, 2005).

As emoções básicas têm uma base neural discreta e consistem em padrões discretos de ativação dentro de uma ampla rede de regiões cerebrais (SAARIMÄKI et al., 2015). Do ponto de vista neurobiológico, a existência das emoções básicas ainda é sustentável e heurísticamente seminal, entretanto, atenta-se para a necessidade de algum tipo de reformulação (CELEGHIN et al., 2017).

Diferentes autores propuseram diferentes visões a respeito de quais emoções poderiam ser enquadradas como emoções básicas. A seguir apresenta-se uma relação de alguns conjuntos formulados (QUADRO 1).

QUADRO 1 - LISTA DE EMOÇÕES BÁSICAS

Emoções básicas	Autor (es)
Raiva (<i>anger</i>), Medo (<i>fear</i>), Tristeza (<i>sadness</i>), Prazer (<i>enjoyment</i>), Nojo (<i>disgust</i>), Surpresa (<i>surprise</i>).	Ekman (1992)
Medo (<i>fear</i>); Surpresa (<i>surprise</i>); Tristeza (<i>sadness</i>); Nojo (<i>disgust</i>); Desprezo (<i>contempt</i>); Felicidade (<i>happiness</i>).	Ekman e Cordaro (2011)
Interesse (<i>interest</i>); Prazer/Felicidade/Contentamento (<i>enjoyment/happiness/contentment</i>); tristeza (<i>sadness</i>); Raiva (<i>anger</i>), Nojo (<i>disgust</i>); Medo (<i>fear</i>).	Izard (2011)
Prazer (<i>enjoyment</i>); Raiva (<i>anger</i>); Nojo (<i>disgust</i>); Medo (<i>fear</i>); Surpresa (<i>surprise</i>); Tristeza (<i>sadness</i>); Alívio/Contentamento/Interesse (<i>relief/contentment, interest</i>); Amor (<i>love</i>).	Levenson (2011)

FONTE: Elaborado pelo Autor com base em Tracy e Randles (2011, p. 399)

Observando-se o Quadro 1, percebe-se que as emoções “raiva”, “medo”, “tristeza” e “nojo” são listadas por todos os autores e que, apesar das variações, todas as listas contêm ao menos uma emoção relacionada a algo positivo (prazer, felicidade, contentamento, alívio). Esta “concordância” quanto à nomenclatura das emoções básicas vai ao encontro do resultado obtido em Ekman (2016).

O pesquisador norte-americano encaminhou um questionário para 248 cientistas - 60% de respostas - questionando qual seria a melhor opção quanto à orientação para a emoção que os cientistas adotaram em suas pesquisas. Dentre os resultados, 74% dos entrevistados ao serem questionados de quais rótulos de emoções deveriam ser considerados empiricamente constatou grande aceitação para as emoções raiva (91%), medo (90%), nojo (86%), tristeza (80%) e felicidade (76%) (EKMAN, 2016, p.32).

Os autores listados no Quadro 1, em resumo, compartilham algumas suposições fundamentais derivadas de uma abordagem evolucionista de Darwin (CELEGHIN et al., 2017). Ademais, há uma concordância de que uma emoção básica deve ser discreta, ter um conjunto fixo de componentes expressos neural e corporais e um componente fixo de sentimento ou motivação (TRACY; RANDLES, 2011).

2.2.2 Abordagem dimensional das emoções

Diferente da abordagem das emoções básicas, os teóricos defensores das abordagens dimensionais compreendem que não há um sistema neural independente

para cada emoção básica, mas sim que as emoções podem ser representadas em um pequeno número de dimensões (RUSSELL, 1980; POSNER; RUSSELL; PETERSON, 2005; EEROLA; VUOSKOSKI, 2011; HAMANN, 2012) sendo as mais utilizadas representadas pela excitação - relacionada à intensidade da orientação emotiva - e a valência - relacionada à direção emotiva (FONTAINE et al., 2007; HAMANN, 2012; HINOJOSA et al., 2016; HARMON-JONES; HARMON-JONES; SUMMERELL, 2017).


Nesta abordagem, as emoções são compreendidas como o produto oriundo de uma interação complexa ocasionada primariamente em estruturas neocorticais e mudanças neurofisiológicas relacionadas aos sistemas de valência e excitação (POSNER; RUSSELL; PETERSON, 2005). Desde as ideias iniciais propostas pelo pesquisador Wilhelm Wundt (WUNDT; 1904) defendendo que as emoções poderiam ser representadas em espaços dimensionais, diferentes abordagens foram elaboradas para a representação dimensional das emoções (VEIRMAN; FONTAINE, 2014; EKMAN, 2016).

Dentre os modelos dimensionais, uma abordagem específica consiste no modelo conhecido como modelo circumplexo de afeto, um modelo composto por 28 adjetivos relacionados à emoção. No modelo em questão, propõe-se que todos os estados afetivos surgem de dois sistemas neurofisiológicos fundamentais, um relacionado à valência (um contínuo prazer-desprazer) e o outro à excitação (RUSSELL, 1980). Neste modelo, cada emoção é entendida como uma combinação linear destas duas dimensões, ou como graus variados destas (POSNER; RUSSELL; PETERSON, 2005; EEROLA; VUOSKOSKI, 2011; HINOJOSA et al., 2016).

No eixo horizontal, estabelece-se os níveis de prazer e desprazer; no eixo vertical, varia-se os graus de excitação. Nesta relação, os quadrantes do modelo têm a seguinte distribuição: a) o primeiro quadrante apresenta os estados com valor negativo para prazer e positivo para excitação (tenso, irritado, ...); b) o segundo quadrante corresponde aos estados com valores positivos de prazer e excitação (feliz, contente, ...); c) o terceiro quadrante condiz com os termos com valor positivo para prazer e grau de excitação negativo (calmo, satisfeito ...); e d) o quarto quadrante é composto por adjetivos com valores negativos de prazer e excitação (triste, melancólico, ...) (RUSSELL, 1980).

O modelo circumplexo de afeto proposto é apresentado na Figura 1.

FIGURA 1 - MODELO CIRCUMPLEXO DE AFETO PROPOSTO POR RUSSELL (1980).




FONTE: Adaptado de Russell (1980, p. 1169).

Entretanto, apesar da sua importância, o próprio autor reconheceu que o modelo não fornecia uma descrição suficientemente rica, uma vez que, por exemplo, não era possível explicar adequadamente como emoções como o medo, o ciúme, a raiva e a vergonha se diferenciavam e nem como os observadores poderiam distingui-las (RUSSELL, 2003).

Desta forma, abordagens considerando mais de duas dimensões foram propostas por autores como Fontaine et al. (2007), Lövheim (2012) e Bakker et al. (2014). O modelo proposto por Fontaine et al. (2007) consiste em um modelo quadridimensional representando 24 termos emocionais. Neste modelo, as emoções são distribuídas nas dimensões valência, potência, excitação e imprevisibilidade (ANEXO A).

O modelo proposto por Lövheim (2012) é um modelo tridimensional de emoções e neurotransmissores monoaminérgicos composto por oito emoções básicas ordenadas em um sistema de coordenadas ortogonais dos três principais eixos monoaminérgicos, sendo estes: 5-hidroxitriptamina (5-HT), dopamina (DA) e noradrenalina (NE). O modelo de Lövheim (2012) é apresentado na Figura 2.

FIGURA 2 - MODELO TRIDIMENSIONAL DE EMOÇÕES PROPOSTO POR LÖVHEIM (2012)

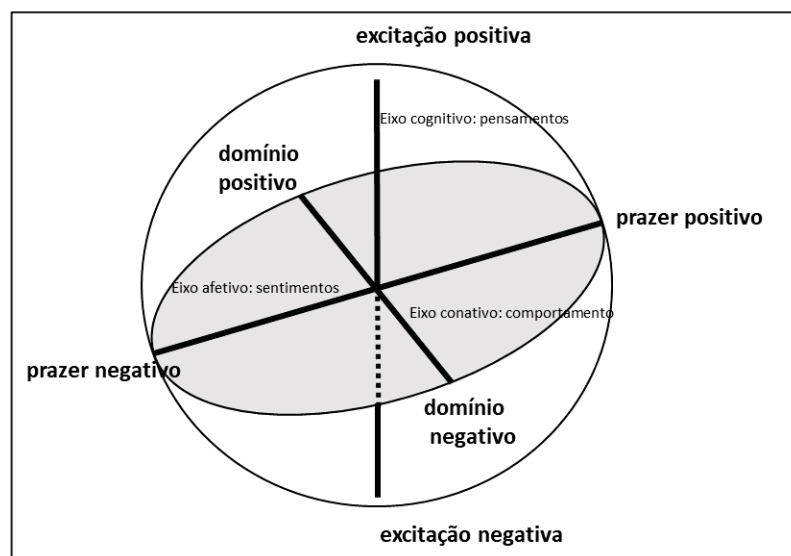


FONTE: Adaptado de Lövheim (2012, p.342).

No modelo proposto por Bakker et al. (2014) os autores consideraram acrescentar à abordagem bidimensional composta pelos eixos prazer e excitação um terceiro eixo denominado como domínio.

O modelo proposto por Bakker et al. (2014) é representado na Figura 3.

FIGURA 3 - MODELO TRIDIMENSIONAL DE EMOÇÕES PROPOSTO POR BAKKER ET AL. (2014)



FONTE: Adaptado de Bakker et al. (2014, p.).

Além deste terceiro eixo, para a formulação do modelo, os autores consideraram ideal conectar as três dimensões à tríade sentimento, pensamento e ação, buscando, desta forma, melhorar a compreensão, a interpretação e a medição das dimensões prazer, excitação e dominância.

2.3 MÚSICA E EMOÇÃO

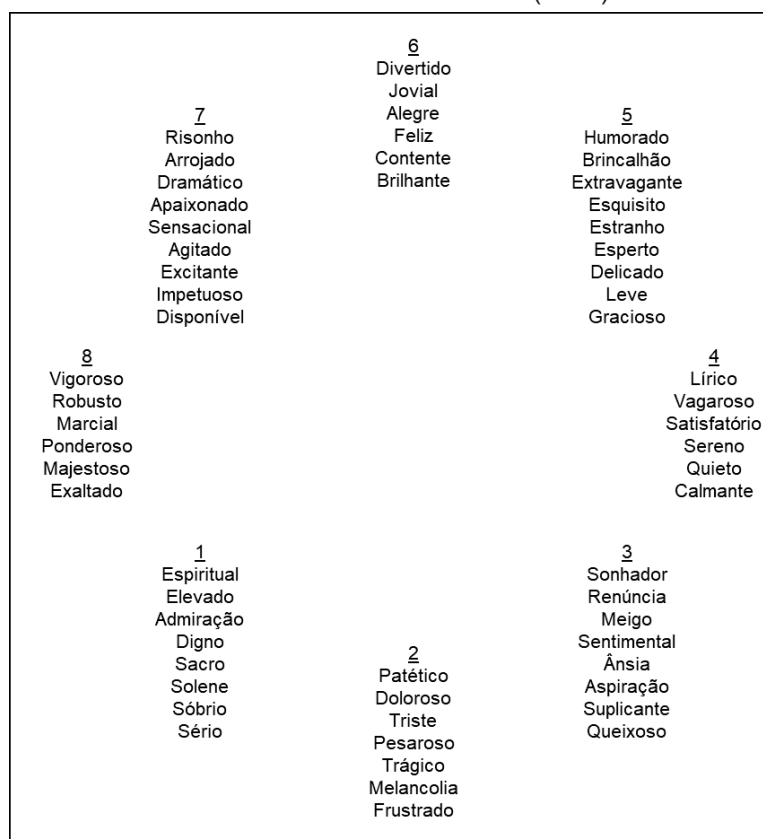
Devido à capacidade de transmitir emoções (GOSSELIN et al. 2007; EEROLA; VUOSKOSKI, 2011; JUSLIN, 2013; DALY et al. 2015), a música consiste em uma valiosa ferramenta para os estudos relacionados à investigação de emoções e seus correlatos neurais (KOELSCH, 2014). Charles Darwin afirmava que a música tinha um “poder maravilhoso”, capaz de recordar emoções de eras passadas e que, assim como algumas emoções fortes - tristeza, alegria, amor e simpatia - eram responsáveis por levar uma pessoa às lágrimas, o mesmo poderia ser atribuído à música (DARWIN, 1998).

A capacidade da música em evocar emoções “fascina” pesquisadores e o público em geral ao longo dos tempos (EEROLA; VUOSKOSKI, 2011). No entanto, a ligação entre música e emoção ainda é mal compreendida (EEROLA; VUOSKOSKI, 2011; SWAMINATHAN; SCHELLENBERG, 2015; HUO et al. 2017). Uma das dificuldades no estudo desta relação consiste no fato da música ser um sinal de áudio altamente complexo que varia ao longo do tempo e da frequência (DALY et al. 2015).

Estudos buscando compreender os fatores da relação entre música e emoções são desenvolvidos desde o início da Psicologia como ciência (SAIZ-CLAR; REALES, 2017), sendo o mais celebrado o trabalho conduzido pela pesquisadora Kate Hevner (HEVNER, 1936; SCHUBERT, 2003; YANG; CHEN; 2011; SHEN et al., 2018) na década de 1930 que resultou em um *checklist* composto por 67 adjetivos emocionais distribuídos em oito grupos (*clusters*).

O *checklist* proposto por Hevner (1936) é representado na Figura 4.

FIGURA 4 - *CHECKLIST* DE ADJETIVOS EMOCIONAIS PROPOSTO POR HEVNER (1936)



FONTE: Adaptado de Lisboa (2008, p. 52)

Em 2003, o pesquisador Emery Schubert (SCHUBERT; 2003) propôs uma atualização do *checklist* desenvolvido por Hevner (1936). O autor conduziu um estudo com 133 voluntários com experiência musical e obteve uma distribuição considerada mais ampla para as faixas emocionais do que as desenvolvidas por Hevner (1936).

A versão atualizada resultou em uma lista composta por 46 adjetivos agrupados em nove *clusters* emocionais (QUADRO 2).

QUADRO 2 - ATUALIZAÇÃO DO *CHECKLIST* DE HEVNER (1936) POR SCHUBERT (2003).

Cluster	Adjetivos
A	Alegre, Animado, Feliz, Jubiloso
B	Humorístico, Leve, Lírico, Festivo, Brincalhão
C	Calmo, Delicado, Gracioso, Quietos, Relaxado, Sereno, Calmante, Meigo
D	Sonhador, Sentimental
E	Trágico, Desejoso
F	Sombrio, Depressivo, Lúgubre, Melancólico, Lamentoso, Triste, Solene
G	Pesado, Majestoso, Sagrado, Sério, Espiritual, Vigoroso
H	Dramático, Excitante, Exaltado, Sensacional, Elevado, Triunfante
I	Agitado, Raivoso, Inquieto, Tenso

FONTE: Adaptado de Fernandes (2017, p.120)

No entanto, apesar de estudos como os de Hevner (1936) e Schubert (2003), sabe-se que as emoções induzidas pela música diferem entre os ouvintes (DALY et al. 2015), pois, algumas pessoas costumam ouvir música para mudar seu humor, enquanto outras para aliviar sentimentos como a depressão, a infelicidade ou algum tipo de desconforto emocional (KAWAKAMI; FURUKAWA; OKANOYA, 2014). Fora deste espectro, ainda, é possível que haja indivíduos que encontram prazer anormal na música (musicofilia), assim como indivíduos que não obtêm nenhum prazer (anedonia musical) (BELFI, 2017).

Contudo, apesar da dificuldade em entender por completo a relação entre música e emoções, Koelsch (2014) afirma que resultados de pesquisas indicam que o prazer evocado pela música está associado à atividade da via de recompensa (incluindo o *nucleus accumbens*). Para o autor, a música tem a capacidade para alterar atividades neuronais em determinadas estruturas cerebrais, gerando implicações para o desenvolvimento de terapias para o tratamento de distúrbios neurológicos e psiquiátricos (KOELSCH, 2014; KOELSCH, 2018).

Utilizada para regular as emoções na vida cotidiana (KOELSCH, 2014; SAKKA; JUSLIN, 2018), há a possibilidade da utilização da música como um recurso contra sintomas de afeto negativo persistente em depressão, por exemplo (SAKKA; JUSLIN, 2018), posto que, estudos sobre correlatos neurais relacionados à ligação entre emoções e música apontam que a música afeta áreas relacionadas diretamente à emoção, como o córtex frontal medial, a amígdala, o corpo estriado, o hipocampo, o córtex cingulado anterior, o *nucleus accumbens* e o córtex orbitofrontal (BRATTICO et al. 2016; HUO et al. 2017).

A música é capaz de evocar mudanças em todos os cinco componentes da emoção: (1) componente cognitivo, relacionado a emoções como prazer ou desprazer; (2) componente motivacional, relacionado a fortes tendências de ação como a dança; (3) componente fisiológico, associado ao relaxamento ou à excitação; (4) componente de expressão, relacionado à expressão facial ao fazer ou ao ouvir música, por exemplo; e (5) componente subjetivo, relacionado à alegria, à coragem, à nostalgia, à tranquilidade, à tristeza, entre outros (KOELSCH, 2018).

Por ser um estímulo valioso e válido, a música é um elemento confiável para a investigação das emoções. Entretanto, tal fato não a torna o principal instrumento de investigação para cada tipo de emoção ou qualquer outro estímulo experimental.

Emoções consideradas “morais”, como nojo ou ciúmes, são difíceis de evocar com música (KOELSCH, 2014).

Emoções como a alegria e a surpresa tendem a ser idênticas às emoções da vida cotidiana, por sua vez, algumas emoções são buscadas na música porque elas podem ocorrer apenas raramente na vida cotidiana como a transcendência (KOELSCH, 2014). Ademais, é provável que a música induza uma ampla gama de emoções por meio de múltiplos mecanismos, provocando respostas positivas e negativas misturadas simultaneamente (SWAMINATHAN; SCHELLENBERG, 2015).

2.4 RECONHECIMENTO DE EMOÇÕES EM MÚSICAS

O reconhecimento de emoções em músicas é uma ferramenta essencial na recomendação de músicas, dado que, usuários geralmente querem músicas para amplificar suas emoções em determinadas situações, como festejar ou dirigir (JEON et al., 2017). Por conta da relação entre emoções e música, o estudo da informação emocional de uma música é um recurso promissor para ser empregado na recuperação e recomendação de músicas (YANG; DONG; LI, 2017; JEON et al., 2017).

Sistemas de reconhecimento de emoções em músicas passaram por um desenvolvimento significativo nos últimos anos (PANDA; ROCHA; PAIVA, 2015; HSIAO; CHEN; LEE, 2017) e suas estratégias baseiam-se no processamento de sinais de áudio e em modelos computacionais para prever emoções expressas pela música (BEVERIDGE; KNOX, 2017).

As abordagens dos sistemas de reconhecimento de emoções em músicas atuais consistem na coleta de informações baseada em *tags* de plataformas como a Last.fm¹ e a The Echo Nest². Por sua vez, os rótulos de emoções empregados estão na forma de rótulos emocionais - também denominados como modelos categóricos ou coordenadas emocionais - referenciados também como modelos paramétricos (CHEN et al., 2015; YANG; DONG; LI, 2017).

Normalmente, o reconhecimento de emoções em músicas é abordado como um problema de reconhecimento de padrões e/ou classificação no qual, em um primeiro momento, a emoção de cada música é anotada por humanos e, em seguida,

¹ Disponível em: <https://www.last.fm/pt/home>. Acesso em 13 jan. 2019.

² Disponível em: <http://the.echonest.com/>. Acesso em 13 jan. 2019.

uma relação de descritores/características destas músicas é extraída para a formulação de um conjunto de dados de treinamento (DROSSOS; FLOROS; GRIGORIOS, 2012).

Nesta abordagem, as emoções são divididas em classes (feliz, irritado, triste...) e, para cada música do conjunto de treinamento, é associado uma emoção. Posterior a esta rotulação, técnicas de aprendizado de máquina são empregadas para treinar um classificador, cujo objetivo é atribuir automaticamente rótulos emocionais para novas músicas (YANG; CHEN, 2009; CHEN et al., 2015).

No reconhecimento de emoções em músicas, a participação humana é necessária para a associação de músicas a rótulos de emoções. Contudo, devido às percepções individuais de emoção ao longo de uma determinada música, é possível que haja um grau de discordância entre os ouvintes. Desta forma, todas as estratégias desenvolvidas encontram “desafios significativos” no que tange à precisão dos recursos informativos para o reconhecimento da emoção musical (SCHMIDT; SCOTT; KIM, 2012; NALINI; PALANIVEL, 2016).

Parte do desafio envolvido existe por conta da falta de clareza de como a música causa emoções (NALINI; PALANIVEL, 2016; JEON et al., 2017). Entretanto, sabe-se que fatores como o tom, o ritmo e as letras estão relacionados para determinar a emoção da música (JEON et al., 2017).

Acerca das estratégias adotadas no reconhecimento de emoções em músicas, recursos relacionados à análise de descritores obtidos por meio de processamento de sinais de áudio (LI; OGIHARA, 2003; SCHMIDT; TURNBULL; KIM, 2010; LIU et al., 2018); às letras (HU; CHEN; YANG, 2009; AN; SUN; WANG, 2017; MALHEIRO et al., 2018); às progressões de acordes (CHOO et al., 2016) e às combinações entre recursos (THAMMASAN; FUKUI; NUMAO, 2017; DELBOUYS et al., 2018) foram utilizados ao longo dos anos (KIM et al., 2010; YANG; CHEN, 2012; YANG; DONG; LI, 2017).

Considerando os trabalhos conduzidos por meio de processamento de sinais de áudio, Li e Ogihara (2003) realizaram um experimento com uma base de dados composta por segmentos de 30 segundos de duração obtidos a partir de um total de 499 músicas. Para o experimento, os autores utilizaram um grupo de descritores relacionados ao timbre, ao ritmo e à altura.

Com relação às emoções utilizadas, a classificação manual foi realizada por um colaborador que distribuiu as músicas em 13 *clusters* compostos por 24 adjetivos

relacionados à emoção. Para a classificação automática, Li e Ogihara (2003) optaram por empregar o algoritmo SVM.

Schmidt, Turnbull e Kim (2010) trabalharam com segmentos de 15 segundos extraídos de 240 músicas. Os autores conduziram um experimento considerando os quatro quadrantes relacionados à excitação (alta, baixa) e à valência (alta, baixa) e trabalharam com descritores como *Mel-Frequency Cepstral Coefficients* (MFCCs). Como estratégia de reconhecimento automático, adotaram uma estratégia de classificação - SVM - e uma estratégia de regressão, por meio do algoritmo *Support Vector Regression* (SVR).

Liu et al. (2018) elaboraram uma estratégia de classificação baseada na análise de espectrogramas extraídos de segmentos de 45 segundos de duração de um total de 1000 músicas, considerando os graus de valência e excitação. Para a tarefa de classificação, os autores realizaram experimentos comparando o desempenho entre uma Rede Neural Convolucional (*Convolutional Neural Network* (CNN)) e o algoritmo SVM (*Support Vector Machine*).

Quanto à análise de letras, Hu, Chen e Yang (2009) trabalharam com a análise de letras de um conjunto de músicas chinesas, considerando os quadrantes relacionados à excitação e valência. Como estratégia de classificação, os autores realizaram um agrupamento *fuzzy*.

An, Sun e Wang (2017) aplicaram o algoritmo Naive Bayes para o reconhecimento de emoções levando em consideração 2369 letras de canções chinesas, distribuídas em três categorias denominadas como depressão, contentamento e exuberância.

Malheiro et al. (2018) abordaram o papel das letras no reconhecimento de emoções em músicas mediante a combinação de características estilísticas, estruturais e semânticas de 180 letras anotadas manualmente de acordo com os quadrantes de excitação e valência. Para validar a estratégia adotada, os autores empregaram as tarefas de classificação e regressão com o algoritmo SVM.

O uso da progressão de acordes para o reconhecimento de emoções em músicas foi considerado por Choo et al. (2016). Nesta estratégia, os autores construíram uma matriz de transição de acordes para cada música que conta a transição dos acordes ao longo do tempo. Os autores consideraram para a rotulação das emoções a distribuição das músicas levando em consideração valência e excitação, respectivamente. Para o reconhecimento automático de emoções, os

experimentos foram realizados por meios dos algoritmos SVR e *Least Absolute Shrinkage and Selection Operator* (LASSO).

Com relação às estratégias que combinam diferentes recursos, Thammasan; Fukui e Numao (2017) apresentaram uma fusão de características relacionadas à análise de eletroencefalograma (EEG) e características musicais extraídas de estímulos musicais em nível de decisão, considerando uma classificação binária composta pelas categorias valência e excitação.

Delbouys et al. (2018) propuseram uma estratégia multimodal baseada no sinal de áudio e nas letras, aplicando diversas estratégias de *deep learning*. Para os experimentos, os autores utilizaram uma base de dados com 18.000 registros devidamente relacionados aos valores de valência e excitação.

A síntese das estratégias elencadas é representada no Quadro 3.

QUADRO 3 - SÍNTESE DAS ESTRATÉGIAS ADOTADAS NO RECONHECIMENTO DE EMOÇÕES EM MÚSICAS

Recurso	Autor (es)	Técnica (s)	Emoções
Áudio	Li e Ogiwara (2003)	Classificação (SVM)	13 <i>clusters</i> compostos por 24 adjetivos relacionados à emoção
	Schmidt, Turnbull e Kim (2010)	Classificação (SVM) e Regressão (SVR)	Valência e Excitação
	Liu et al. (2018)	Classificação (rede neural convolucional e SVM)	Valência e Excitação
Letras	Hu, Cheng e Yang (2009)	Agrupamento <i>fuzzy</i>	Valência e Excitação
	An, Sun e Wang (2017)	Classificação (Naive Bayes)	Depressão, contentamento e exuberância
	Malheiro et al. (2018)	Classificação e Regressão (SVM)	Valência e Excitação
Progressão de acordes	Choo et al. (2016)	Regressão (SVR e LASSO)	Valência e Excitação
Multimodal	Thammasan; Fukui e Numao (2017)	Classificação (SVM)	Valência e Excitação
	Delbouys et al. (2018)	<i>Deep Learning</i>	Valência e Excitação

FONTE: Elaborado pelo Autor (2019).

A seguir, apresenta-se os conceitos relacionados à lógica *fuzzy*.

2.5 LÓGICA FUZZY

O conceito de lógica *fuzzy* remete ao trabalho “*Fuzzy Sets*” publicado em 1965 pelo professor Lotfi A. Zadeh, docente do departamento de engenharia elétrica da

Universidade da Califórnia (ZADEH, 1965; NGUYEN; WALKER; WALKER, 2018). Apesar de ser vista como uma lógica multivalorada (SUGANTHI; INIYAN; SAMUEL, 2015), esta visão consiste em uma percepção restrita da lógica *fuzzy*, devido a esta ser muito mais que um sistema lógico (ZADEH, 2015), caracterizando-se como uma alternativa à lógica binária que só admite a existência de verdadeiro e falso, não admitindo qualquer tipo de imprecisão entre estes dois extremos (ROSS, 2005; BĚLOHLÁVEK; DAUBEN; KLIR, 2017).

A visão binária é “comum” na ciência, contudo, na cognição humana, é exceção (ZADEH, 2015). Desta forma, a lógica *fuzzy* fornece uma estrutura conceitual para lidar com a representação do conhecimento em ambientes cercados de incerteza e imprecisão, caracterizando-se como uma extensão dos sistemas lógicos clássicos, (ZADEH, 1992) e como um sistema de raciocínio e cálculo no qual seus objetos de estudo são classes com limites não definidos (ZADEH, 2015).

Na lógica *fuzzy*, os valores de verdade absolutos não são abandonados. Entretanto, trabalha-se com valores de verdade intermediários entre os extremos verdadeiro e falso, podendo-se atribuir a qualquer proposição não apenas valores como 1 (verdadeiro) ou 0 (falso), mas também outros graus de verdade intermediários (BĚLOHLÁVEK; DAUBEN; KLIR, 2017).

Neste aspecto, compreende-se a lógica *fuzzy* como uma tentativa de formalização da capacidade de tomar decisões racionais em cenários repletos de imprecisão e incerteza, compostos de informações incompletas e ambíguas, ou seja, cercados de informação imperfeita (ZADEH, 2008).

2.5.1 Conjuntos *fuzzy*

Um conjunto *fuzzy* - ou conjunto difuso - é um conjunto caracterizado por uma função de pertinência que atribui a cada objeto um grau de pertinência que varia entre zero e um (ZADEH, 1965). Os conjuntos *fuzzy* lidam com a incerteza presente quando os limites de uma classe de objetos não são nitidamente definidos.


Por exemplo, a associação a termos como “jovem” ou “renda alta” é uma questão de grau e não de certeza, uma vez que, não constituem classes ou conjuntos no sentido matemático (ZADEH, 1965; NGUYEN; WALKER; WALKER, 2018). Contudo, a utilização destes termos desempenha um papel importante no pensamento humano (ZADEH, 1965).

Estratégias baseadas em conjuntos *fuzzy* são úteis em contextos que demandam sistemas altamente complexos, cujos comportamentos não são bem compreendidos (ROSS, 2005).

Do ponto de vista matemático, um conjunto *fuzzy* pode ser representado da seguinte maneira: dado um conjunto *fuzzy* A em um universo X, tem-se uma função de pertinência $f_A(x)$ que associa cada ponto em X a um número real no intervalo [0, 1]. Desta forma, na função de pertinência $f_A(x)$, o valor de x representa o grau de pertinência de x no conjunto *fuzzy* A. Sendo assim, quanto mais próximo o valor de $f_A(x)$ de 1, maior é o grau de pertinência de x em A (ZADEH, 1965).

Normalmente, refere-se à letra X para a representação de um universo – também denominado universo do discurso - e este pode ser composto por elementos discretos (ordenados ou não ordenados) ou um por valores contínuos (JANG, 1997a), conforme demonstra-se na Figura 5.

FIGURA 5 - CONJUNTOS FUZZY COM UNIVERSO DISCRETO E CONTÍNUO



FONTE: Adaptado de Jang (1997, p. 15)

Na Figura 5 percebe-se, à esquerda, o universo X composto por elementos discretos, cujos valores representam o número de filhos. Por sua vez, o universo X, à direita, corresponde à representação de um universo com valores contínuos, representando valores correspondentes à idade.

No que tange às operações matemáticas envolvendo conjuntos *fuzzy*, assume-se que um conjunto *fuzzy* é vazio se, e somente se, possuir uma função de pertinência igual a zero em um universo X (ZADEH, 1965). Considerando dois conjuntos *fuzzy* (A e B), é possível estabelecer operações básicas como união, intersecção e complemento (ZADEH, 1965; NGUYEN; WALKER; WALKER, 2018).

Estas operações são representadas pelas equações 1,2 e 3.


União	$(A \vee B)(x) = \max \{A(x), B(x)\} = A(x) \vee B(x)$	(1)
-------	--	-----

Intersecção	$(A \wedge B)(x) = \min \{A(x), B(x)\} = A(x) \wedge B(x)$	(2)
-------------	--	-----

Complemento	$A'(x) = 1 - A(x)$	(3)
-------------	--------------------	-----

Do ponto de vista gráfico, estas operações são representadas pela Figura 6.

FIGURA 6 - REPRESENTAÇÃO GRÁFICA DAS OPERAÇÕES BÁSICAS DE CONJUNTOS *FUZZY*



FONTE: Adaptado de Jang (1997, p. 23).

Observando-se a Figura 6 (a), nota-se a representação para os conjuntos *fuzzy* A e B. A Figura 6 (b) corresponde à representação do complemento do conjunto A. A representação da união dos conjuntos A e B ($A \vee B$) é visualizada na Figura 6 (c). Por fim, a Figura 6 (d) corresponde à intersecção dos conjuntos A e B ($A \wedge B$).


2.5.2 Funções de pertinência

Ao trabalhar-se com a lógica *fuzzy* uma das dificuldades consiste na escolha adequada de uma função de pertinência (GONZALEZ et al., 2014). Usualmente, é comum adotar-se quatro tipos de funções de pertinência: 1) função triangular; 2)

função trapezoidal; 3) função gaussiana; e 4) função seno generalizada (JANG, 1997a).

Uma função de pertinência do tipo triangular é composta por três parâmetros $\{a, b, c\}$, com $\{a < b < c\}$, que determinam as coordenadas x que formam a estrutura triangular que representa esta função de pertinência, conforme observa-se na Figura 7.

FIGURA 7 - FUNÇÃO DE PERTINÊNCIA TRIANGULAR




FONTE: Jang (1997a, p. 26).

A função triangular representada na Figura 7 é composta pelos valores $\{20, 60, 80\}$. A representação matemática de uma função triangular é demonstrada na Equação 4.

$$triângulo(x; a, b, c) = \begin{cases} 0, & x \leq a. \\ \frac{x - a}{b - a}, & a \leq x \leq b. \\ \frac{c - x}{c - b}, & b \leq x \leq c. \\ 0, & c \leq x. \end{cases} \quad (4)$$

Uma função de pertinência do tipo trapezoidal caracteriza-se pela utilização de quatro parâmetros $\{a, b, c, d\}$, com $\{a < b < c < d\}$, que determinam as coordenadas x que formam a estrutura trapezoidal que representa esta função de pertinência, conforme exposto na Figura 8.

FIGURA 8 – FUNÇÃO DE PERTINÊNCIA
TRAPEZOIDAL




FONTE: Jang (1997a, p. 26).

A função trapezoidal representada na Figura 8 é composta pelos valores {10, 20, 60, 95}. A formulação matemática desta função é demonstrada na Equação 5.

$$\text{trapézio}(x; a, b, c, d) = \begin{cases} 0, & x \leq a. \\ \frac{x - a}{b - a}, & a \leq x \leq b. \\ 1, & b \leq x \leq c. \\ \frac{d - x}{d - c}, & c \leq x \leq d. \\ 0, & d \leq x. \end{cases} \quad (5)$$

Funções de pertinência do tipo gaussiana são compostas por dois parâmetros { c , σ }, em que c representa o centro da função e σ a largura desta função, conforme apresentado na Figura 9.

FIGURA 9 - FUNÇÃO DE PERTINÊNCIA GAUSSIANA




FONTE: Jang (1997a, p. 26).

A função gaussiana representada na Figura 9 é composta pelos valores {50, 20}. A formulação matemática desta função é demonstrada na Equação 6.

$$gaussiana(x; c, \sigma) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2} \quad (6)$$

Por fim, a função de pertinência do tipo Sino Generalizada – ou somente sino – é composta por três parâmetros {a, b, c}, com os parâmetros a e c relacionados à variação do centro e da largura da função, respectivamente. Por sua vez, o parâmetro b - geralmente representado por um valor positivo – é responsável pela inclinação da função, conforme representado na Figura 10.

FIGURA 10 - FUNÇÃO DE PERTINÊNCIA SINO



FONTE: Jang (1997a, p. 26).

A função do tipo sino generalizada representada na Figura 10 é composta pelos valores {20, 4, 50}. A formulação matemática desta função é demonstrada na Equação 7.

$$\text{sino}(x; a, b, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}} \quad (7)$$

Funções de pertinência não se limitam a apenas estes quatro tipos, sendo possível estabelecer funções de pertinência dos tipos L e R, por exemplo (PEKALA, 2018). Além disto, muitas vezes, diferentes funções de pertinência são atribuídas ao mesmo conceito *fuzzy* (NGUYEN; WALKER; WALKER, 2018), pois a forma de construir este tipo de função nem sempre é evidente, acarretando em grandes dificuldades (BUSTINCE et al., 2016).

2.5.3 Fuzzificação e Defuzzificação

A etapa denominada fuzzificação consiste no processo em que um valor *crisp* é convertido em um valor *fuzzy* (ROSS, 2005). Neste processo, os valores das entradas de um determinado problema são convertidos em variáveis linguísticas, como, por exemplo, termos como “baixo”, “médio”, “alto” e “muito alto”. Adiante, com base nas funções de pertinência adotadas, um determinado grau de pertinência é estabelecido, de acordo com a base de regras *fuzzy* elaborada para o problema em questão (CHEN; JHANG; LIANG, 2016).

Matematicamente, a fuzzificação estabelece o grau de pertinência de um valor nítido (*crisp*) $x_i \in X$ a um conjunto *fuzzy* A_{xi} (SIDDIQUE; ADELI, 2013). Siddique e Adeli (2013) argumentam que há dois tipos de fuzzificação, sendo estes:

- a) *Singleton*: mapeia um valor real $x_i \in X$ em um conjunto *fuzzy* A_{xi} , que possui valor de pertinência 1 em $x = x_i$ e 0 para todos os outros pontos em X . É representado na Equação 8:

$$u_{A_{xi}}(x) = \begin{cases} 1 & \text{se } x = x_i \\ 0 & \text{caso contrário} \end{cases} \quad (8)$$

Este tipo de fuzzificação simplifica bastante a computação, contudo, geralmente é aplicada em problemas sem a presença de ruídos (SIDDIQUE; ADELI, 2013).

- b) A_{x_i} é *fuzzy*: mapeia um $x_i \in X$ real em um conjunto *fuzzy* A_{x_i} em X descrito por uma função de pertinência (EQUAÇÃO 9):

$$u_{x_i}(x) = \begin{cases} 1 & \text{se } x = x_i \\ [0,1] & \text{diminuindo conforme a variação de } x \text{ em } x_i \end{cases} \quad (9)$$

Por sua vez, a etapa de defuzzificação é o processo inverso da fuzzificação, ou seja, caracteriza-se pela conversão de um valor *fuzzy* em um valor nítido (*crisp*) compreensível (AKKURT, S.; TAYFUR, G.; CAN, 2004; AL-JARRAH; ABU-QDAIS, 2006; GAO et al., 2019). Para este processo, diversos métodos podem ser empregados (BOBYR; MILOSTNAYA; KULABUHOV, 2017), como, por exemplo:

- *Center of gravity (CoG)*: consiste no método de defuzzificação mais conhecido (LIU, 2007). Calcula o centro de gravidade da área sob a função de pertinência (LIU, 2007). É calculado com base na Equação 10 (LIU, 2007, p.179).

$$CoG(A) = \frac{\int_a^b x \mu_{A(x)} dx}{\int_a^b \mu_{A(x)} dx} \quad (10)$$

- *First of Maxima (FoM)*: este método seleciona como valor para a defuzzificação o menor valor presente em um *core* (A) (LIU, 2007);
- *Last of Maxima (LoM)*: este método seleciona como valor para a defuzzificação o maior valor presente em um *core* (A) (LIU, 2007);
- *Middle of Maxima (MoM)*: consiste em obter a média entre o maior valor e o menor valor de um *core* (A) (LIU, 2007). Obtido por meio da Equação 11 (LIU, 2007, p.179).

$$Mom(A) = \frac{\min core(A) + \max core(A)}{2} \quad (11)$$

Na sequência apresenta-se os conceitos relacionados aos sistemas de inferência *fuzzy*.

2.5.4 Sistemas de inferência *fuzzy*

Um sistema de inferência *fuzzy* (*Fuzzy Inference System*) permite expressar situações incertas em forma de regras (KARABOGA; KAYA, 2018) e caracteriza-se como a ferramenta de modelagem mais importante baseada na lógica *fuzzy* (JANG, 1997c). Consiste em um sistema composto por um conjunto de etapas sequenciais em que a lógica *fuzzy* é utilizada para modelar o processo de tomada de decisão (BALAL; CHEU, 2018).

A estrutura básica de um sistema de inferência *fuzzy* consiste em três módulos: a) base de regras, composta por um conjunto de regras *fuzzy*; b) base de dados (dicionário), relacionada às funções de pertinência aplicadas às regras *fuzzy*; e c) mecanismo de inferência, que executa as inferências sobre as regras para a obtenção de uma saída ou conclusão razoável (JANG, 1997b; AL-JARRAH; ABU-QDAIS, 2006).

A respeito das regras *fuzzy*, estas são expressas por meio de uma condição se-então (*if-then*), do tipo “se x é A então y é B” (DUBOIS; PRADE, 1996; JANG, 1997c), em que A e B correspondem a valores linguísticos definidos por conjuntos *fuzzy* em universos X e Y, respectivamente. De forma geral, “x é A” é denominado de antecedente ou premissa, enquanto “y é B” é denominado consequência ou conclusão (JANG, 1997c).

Comparadas às regras convencionais (não *fuzzy*), as regras *fuzzy* têm limites suaves que diminuem de forma gradual o suporte para uma classe, variando de um suporte completo (totalmente inserido) a um suporte nulo (próximo ao limite). Por sua vez, as regras convencionais apresentam transições abruptas entre diferentes classes (HÜHN; HÜLLERMEIER, 2009).

Com relação aos mecanismos de inferência, os sistemas mais disseminados consistem nos propostos por Mamdani (MAMDANI; ASSILIAN, 1975); Sugeno (TAKAGI; SUGENO, 1985); e Tsukamoto (TSUKAMOTO, 1979) (JANG, 1997b; AL-

JARRAH; ABU-QDAIS, 2006; KOVAC et al., 2013; SARI; WAHYUNGGORO; FAUZIATI, 2016).

O sistema de inferência de Mamdani é, em termos de uso, o sistema de inferência *fuzzy* mais utilizado, uma vez que apresenta uma estrutura relativamente simples, além de uma natureza intuitiva e interpretável (KOVAC et al., 2013) que facilita a absorção do conhecimento qualitativo (GAO et al., 2019).

O sistema de inferência de Mamdani foi baseado em uma tentativa de controlar uma máquina a vapor por meio de regras linguísticas obtidas de operadores experientes (MAMDANI; ASSILIAN, 1975; JANG, 1997b) e caracteriza-se por representar os consequentes de suas regras por meio de conjuntos *fuzzy* (AL-JARRAH; ABU-QDAIS, 2006).

Um sistema de inferência de Mamdani com entrada e saída simples pode ser expresso pelas seguintes regras:

1. Se X é pequeno então Y é pequeno
2. Se X é médio então Y é médio
3. Se X é grande então Y é grande (JANG, 1997b, p. 77).

A saída do sistema de Mamdani apresenta-se como um conjunto *fuzzy* que, geralmente, é submetido a um processo de defuzzificação (JANG, 1997b; AL-JARRAH; ABU-QDAIS, 2006; KOVAC et al., 2013; SARI; WAHYUNGGORO; FAUZIATI, 2016).

O sistema de inferência de Sugeno (também conhecido como Takagi e Sugeno (TKS)) caracteriza-se por apresentar como consequente uma equação que consiste em uma representação linear local da relação entre a entrada e a saída do sistema (GAO et al., 2019).

No sistema de inferência em questão, uma regra *fuzzy* pode ser representada da seguinte maneira: se x é A e y é B, então $z = f(x, y)$; em que os antecedentes “A” e “B” são conjuntos *fuzzy*, enquanto o consequente “ $z = f(x, y)$ ” corresponde a uma função *crisp* (JANG, 1997b).

Um sistema de inferência de Sugeno com uma entrada simples pode ser representado pelas seguintes regras:

4. Se X é pequeno então $Y = 0,1X + 6,4$
5. Se X é médio então $Y = -0,5X + 4$
6. Se X é grande então $Y = X - 2$ (JANG, 1997b, p.82).

O sistema de Sugeno apresenta-se como uma escolha ideal no que tange à modelagem *fuzzy* baseada em amostras, posto que não há o esforço relacionado ao processo demorado e matematicamente intratável da operação de defuzzificação (JANG, 1997b).

No sistema de inferência de Tsukamoto, o consequente de uma regra *fuzzy* é representado por um conjunto *fuzzy* com uma função de pertinência monotônica (JANG, 1997b; SON; VAN VIET; VAN HAI, 2017).

Um sistema de inferência de Tsukamoto com uma entrada simples pode ser expresso pelas seguintes regras:

7. Se X é pequeno então Y é C₁
8. Se X é médio então Y é C₂
9. Se X é grande então Y é C₃ (JANG, 1997b, p.85).

O sistema em questão, em comparação com os sistemas de Mamdani e Sugeno, não é empregado com frequência em virtude de não ser tão transparente quanto estes (JANG, 1997b).

Analisando-se os três sistemas de inferência elencados, verifica-se que, em suma, estes diferem-se, principalmente, no tocante à representação dos consequentes das regras *fuzzy* e, desta forma, apresentam procedimentos de agregação e defuzzificação diferentes (AL-JARRAH; ABU-QDAIS, 2006; SARI; WAHYUNGGORO; FAUZIATI, 2016).

2.6 SISTEMAS NEURO-FUZZY

Sistemas neuro-*fuzzy* consistem na combinação das arquiteturas oriundas das redes neurais artificiais e dos conceitos relacionados à lógica *fuzzy* (NAUCK; KRUSE, 1997; SYAHPUTRA, 2016; KARABOGA; KAYA, 2018). De maneira concisa, trata-se de um método híbrido em que um sistema *fuzzy* é treinado por um algoritmo de aprendizagem baseado em redes neurais artificiais (NAUCK; KRUSE, 1997).

Os sistemas neuro-*fuzzy* são sistemas *fuzzy* que utilizam a teoria das redes neurais artificiais para a determinação de suas propriedades - conjuntos *fuzzy* e regras *fuzzy* - por meio da aplicação das propriedades matemáticas das redes neurais artificiais (GÜLER; ÜBEYLI, 2005; ATSALAKIS; PROTOPAPADAKIS; VALAVANIS, 2015). Contudo, não se deve interpretar este tipo de sistema como um sistema

especialista, dado que, há pouca relação com a lógica *fuzzy* no sentido restrito (NAUCK; KRUSE, 1997).

Neste cenário, a integração destes elementos resulta em uma relação na qual se explora os recursos de aprendizagem e a eficiência das redes neurais, juntamente com a capacidade de representação do conhecimento especializado da lógica *fuzzy* (MITRA; HAYASHI, 2000; CERVANTES et al., 2017). Neste sentido, por exemplo, as regras *fuzzy* - por conta da característica de aprendizagem das redes neurais - podem ser obtidas a partir de um conjunto de dados de treinamento (MANOGARAN; VARADHARAJAN; PRIYAN, 2017).

A motivação para o emprego deste método híbrido consiste em contornar as desvantagens individuais de cada estratégia, em razão de as redes neurais apresentarem um comportamento “caixa-preta”³, além de não fornecerem um bom desempenho para a representação do conhecimento (MITRA; HAYASHI, 2000; CERVANTES et al., 2017). Por sua vez, a lógica *fuzzy* não apresenta recursos relacionados à aprendizagem automática e, além disso, existe um trabalho “problemático” no tocante à definição de valores de pertinência adequados para a construção dos sistemas *fuzzy* (MITRA; HAYASHI, 2000; CERVANTES et al., 2017).

Sistemas neuro-*fuzzy* podem ser aplicados em diferentes áreas, como a Saúde (AHMED et al., 2017), a Computação Afetiva (MOTAMED; SETAYESHI; RABIEE, 2017; WANG et al., 2018), as Geociências (SHARMA; VISHAL; SINGH, 2017; TERMEH et al., 2018) e a Psicologia (CHATTOPADHYAY, 2017). Na área da Saúde, por exemplo, uma das utilizações de sistemas neuro-*fuzzy* consiste no diagnóstico da doença de Crohn por meio da análise de imagens médicas relacionadas à doença (AHMED et al., 2018).

Em termos de aplicações na computação afetiva, sistemas neuro-*fuzzy* foram empregados para o reconhecimento de emoções mediante análise de falas, demonstrando ser uma opção “poderosa” para esta tarefa (MOTAMED; SETAYESHI; RABIEE, 2017). Outra aplicação destes sistemas na computação afetiva consiste na análise de imagens como forma de identificar-se graus afetivos relacionados à

³ Denomina-se um método como “caixa-preta” quando este utiliza representações de difícil compreensão para os seres humanos, empregando, por exemplo, conceitos matemáticos complexos. Como exemplo de métodos “caixa-preta”, pode-se citar as redes neurais artificiais e as máquinas de vetores de suporte (BIANCHI, 2008, p.27).

valência, à excitação e à dominância, por meio de descritores relacionados à cor, à morfologia e à textura das imagens (WANG et al., 2018).

Na Psicologia, sistemas neuro-*fuzzy* podem ser empregados como fonte de apoio para diagnosticar a gravidade dos casos de depressão (CHATTOPADHYAY, 2017). Na área de Geociências, aplicações de sistemas neuro-*fuzzy* resultaram em estudos relacionados ao mapeamento da suscetibilidade a inundações no município de Jahrom, na província de Fars, no Irã (TERMEH et al., 2018) e ao desenvolvimento de um modelo para a previsão da permeabilidade ao CO₂ do carvão betuminoso (SHARMA; VISHAL; SINGH, 2017).

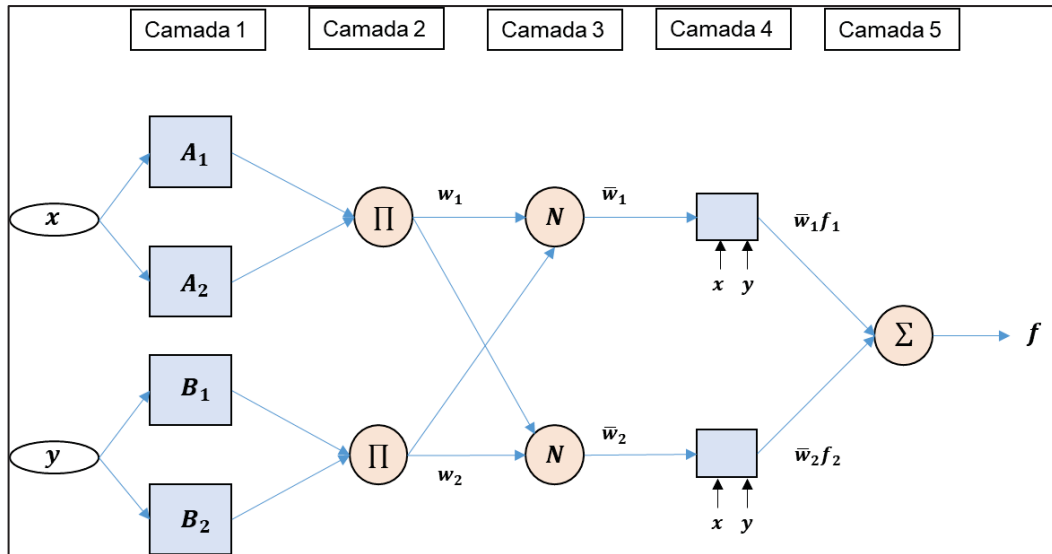
2.7 ADAPTIVE NEURO FUZZY INFERENCE SYSTEM (ANFIS)

Uma estrutura específica relacionada aos sistemas neuro-*fuzzy* consiste na proposta desenvolvida por Jang (1993) denominada *Adaptive Neuro-Fuzzy Inference System* (ANFIS) (JANG, 1993; YAİCI; ENTCHEV, 2016). Nesta estrutura, por exemplo, as funções de pertinência são extraídas a partir de um conjunto de dados e, após o processo de aprendizagem, a estrutura pode adaptar os parâmetros do sistema baseado em um critério de erro especificado (WANG et al., 2018).

A estrutura ANFIS é baseada no modelo de inferência *fuzzy* do tipo Sugeno e não usa pesos sinápticos, mas sim nós adaptativos e não adaptativos (nós fixos) distribuídos em camadas (MANOGARAN; VARADHARAJAN; PRIYAN, 2017). O aprendizado da estrutura é realizado mediante um conjunto de dados de treinamento e, posteriormente, verifica-se o desempenho em um conjunto de testes, sendo que quanto menor os valores de erro, maior é a adequação do modelo (KARABOGA; KAYA, 2018).

Em termos de arquitetura, esta é composta por cinco camadas (JANG, 1993), conforme apresenta-se na Figura 11.

FIGURA 11 - ESTRUTURA ANFIS



FONTE: Adaptado de Bui et al. (2012, p. 203).

No que se refere aos nós, a estrutura ANFIS apresenta dois tipos: a) nós adaptativos, representados por quadrados, cujos parâmetros podem ser ajustados ao longo do processo de aprendizagem; e b) nós fixos (não adaptativos), representados por círculos, cujos parâmetros são fixados no sistema (BUI et al., 2012).

A primeira camada é composta por nós adaptativos e caracteriza-se por realizar a etapa de fuzzificação do modelo. Nesta camada, os valores de entrada são associados às funções de pertinência definidas, em que as saídas podem ser representadas pelas Equações 12 e 13:

$$O_{1,i} = \mu_{A_i}(x) \quad (12)$$

$$O_{1,i} = \mu_{B_i}(y) \quad (13)$$

Em que, para $i = 1, 2$, x e y correspondem às variáveis de entrada do sistema; A e B são variáveis linguísticas; $\mu_{A_i}(x)$ e $\mu_{B_i}(y)$ representam as funções de pertinência (JANG, 1993; BUI et al., 2012; WANG et al., 2018).

A segunda camada - representada pelo símbolo Π (produtório) – simboliza a camada das regras *fuzzy*. É composta por nós fixos e a saída de cada nó é o produto de todos os sinais recebidos (JANG, 1993; BUI et al., 2012; WANG et al., 2018).

Pode ser representada pela Equação 14:

$$O_{2,i} = \omega_i = \mu_{A_i}(x) \mu_{B_i}(y), i = 1,2 \quad (14)$$

A terceira camada - representada por N - é formada por nós fixos e corresponde às operações de normalização para a adequação das regras geradas na segunda camada (JANG, 1993; BUI et al., 2012; WANG et al., 2018).

Os resultados desta camada são calculados pela Equação 15:

$$O_{3,i} = \bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2}, i = 1,2 \quad (15)$$

A quarta camada corresponde ao processo de defuzzificação do sistema e é composta por nós adaptativos e, para cada nó, aplica-se a Equação 16:

$$O_{4,i} = \bar{\omega}_i f_i = \omega_i(p_i x + q_i y + r_i), i = 1,2 \quad (16)$$

Onde $\bar{\omega}_i$ é a saída da terceira camada e o conjunto $\{p_i, q_i, r_i\}$ representa os parâmetros do consequente (JANG, 1993; BUI et al., 2012; WANG et al., 2018).

A quinta camada é composta por um único nó fixo representado pelo símbolo Σ (somatório) e representa a saída total do sistema, somando as saídas obtidas para cada uma das regras presentes na camada de defuzzificação (quarta camada) (JANG, 1993; BUI et al., 2012; WANG et al., 2018).

O cálculo correspondente a esta camada é representado pela Equação 17:

$$O_{5,i} = \sum_i \bar{\omega}_i f_i = \frac{\sum_i \bar{\omega}_i f_i}{\sum_i \bar{\omega}_i}, i = 1,2 \quad (17)$$

Quanto à saída final – representada por f – obtida na quinta camada, esta é dada pela Equação 18:

$$\begin{aligned} f &= \frac{\omega_1}{\omega_1 + \omega_2} f_1 + \frac{\omega_2}{\omega_1 + \omega_2} f_2 = \bar{\omega}_1 f_1 + \bar{\omega}_2 f_2 = \\ &(\bar{\omega}_1 x) p_1 + (\bar{\omega}_1 y) q_1 + (\bar{\omega}_1) r_1 + (\bar{\omega}_2 x) p_2 + \\ &(\bar{\omega}_2 y) q_2 + (\bar{\omega}_2) r_2 \end{aligned} \quad (18)$$

Relativo ao aprendizado da estrutura ANFIS, este consiste em dois processos denominados como *forward pass* e *backward pass*, respectivamente (JANG, 1993; BUI et al., 2012; WANG et al., 2018).

No processo *forward pass*, os parâmetros do consequente (camada 4) são determinados por meio dos mínimos quadrados (JANG, 1993; BUI et al., 2012; WANG et al., 2018). No processo *backward pass*, os parâmetros do consequente são fixados e os erros são propagados para trás, enquanto os parâmetros da premissa são atualizados pelo método gradiente descendente (JANG, 1993; BUI et al., 2012; WANG et al., 2018).

Apresentados os principais conceitos relacionados, a próxima seção apresenta os encaminhamentos metodológicos.

3 ENCAMINHAMENTOS METODOLÓGICOS

Esta seção apresenta a metodologia proposta para este trabalho. Descreve a caracterização da pesquisa quanto à sua natureza, ao seu nível, ao seu delineamento e à sua finalidade. Além disso, apresenta os procedimentos de análise e coleta de dados determinados para a pesquisa.

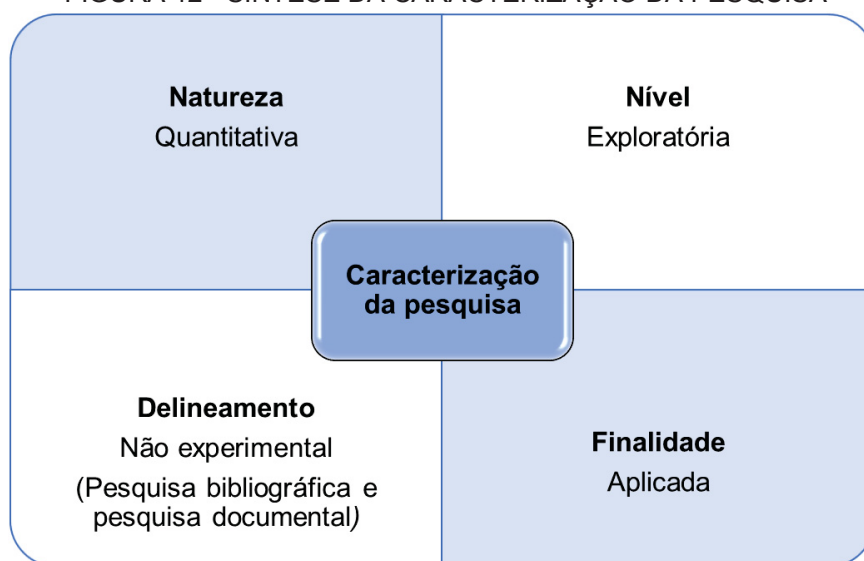
3.1 CARACTERIZAÇÃO DA PESQUISA

Esta pesquisa caracteriza-se como uma pesquisa de natureza quantitativa, apresentando-se como uma pesquisa exploratória, pois almeja preencher uma lacuna existente em relação à produção científica do tema explorado, bem como busca proporcionar uma visão geral a respeito de como os conceitos dos sistemas neuro-*fuzzy* podem ser empregados no reconhecimento de emoções em músicas (GIL, 2008).

Quanto ao seu delineamento, trata-se de uma pesquisa não experimental, cuja coleta de dados é composta por pesquisa bibliográfica, constituída na busca e na leitura de artigos científicos, anais de eventos e livros que abordam os conteúdos necessários para a realização do estudo. A coleta de dados concentra-se, ainda, na pesquisa documental por meio da coleta de arquivos .mp3 diretamente do *YouTube*. Por fim, quanto à sua finalidade, apresenta-se como uma pesquisa aplicada (GIL, 2008).

A caracterização desta pesquisa é sintetizada na Figura 12.

FIGURA 12 - SÍNTESE DA CARACTERIZAÇÃO DA PESQUISA



FONTE: Elaborado pelo Autor (2019).

Posterior à apresentação da caracterização da pesquisa, a seguir descreve-se os procedimentos destinados à coleta e à análise dos dados.

3.2 COLETA E ANÁLISE DE DADOS

Visando atender a cada um dos objetivos específicos definidos, adotou-se um conjunto de procedimentos destinados à coleta e à análise de dados conforme apresentado no Quadro 4.

QUADRO 4 - PROCEDIMENTOS DE COLETA E ANÁLISE DE DADOS

(continua)

Objetivo	Procedimentos	Como	Principais autores
Identificar a taxonomia de emoções a ser utilizada	<p>Analisar a literatura sobre emoções</p> <p>Analisar os modelos já empregados em estudos semelhantes</p>	Pesquisa bibliográfica	<p>Russell (1980); Ekman (1992); Kim et al. (2010); Yang e Chen (2012) Ekman (2016); Jeon et al. (2017)</p>

FONTE: Elaborado pelo autor (2019).

QUADRO 4 - PROCEDIMENTOS DE COLETA E ANÁLISE DE DADOS

(conclusão)

Objetivo	Procedimentos	Como	Principais autores
Construir uma base de dados composta por um conjunto de descritores	Identificar as músicas e suas emoções Coletar as músicas identificadas Extraír os descritores obtidos do sinal de áudio	Pesquisa documental/ bibliográfica Busca na plataforma LastFm Extração do YouTube mediante uso de Python (youtube-dl ⁴) Extração de descritores do sinal do áudio de 30 segundos com o uso de Python (Librosa ⁵)	Tzanetakis e Cook (2002); McKay (2010); Panda e Paiva (2011); McFee et al. (2015); Zhang et al. (2016); Aljanaki, Yang, Soleymani (2017); Pollacci et al. (2018)
Comparar os resultados frente aos obtidos com outros métodos de classificação	Analisar estudos com comparações entre a estrutura ANFIS e outros métodos	Pesquisa bibliográfica	Jang (1993); Dogantekin et al. (2010); Goyal et al. (2014); Balabanova et al. (2016); Motamed, Setayeshi e Rabiee (2017)

FONTE: Elaborado pelo autor (2019).

Na sequência, apresenta-se os procedimentos referentes à criação da base de dados utilizada neste estudo.

3.3 CRIAÇÃO DA BASE DE DADOS

Tendo em vista a dificuldade em se obter bases de dados públicas relacionadas ao reconhecimento de emoções em músicas (YANG; CHEN, 2012; ALJANAKI; YANG; SOLEYMANI, 2017), desenvolveu-se uma base constituída por 877 registros de 30 segundos cada, composta por 28 descritores obtidos por meio da análise do sinal do áudio. Quanto às emoções empregadas, considerou-se o conjunto de emoções conhecidas como “emoções básicas” (EKMAN, 1992; EKMAN; CORDARO, 2011; IZARD, 2011; LEVENSON, 2011).

⁴ Disponível em: < <http://ytdl-org.github.io/youtube-dl/>>. Acesso em: 26 jun. 2019.

⁵ Disponível em: < <https://librosa.github.io/librosa/>>. Acesso em: 26 jun. 2019.

Neste estudo, o conjunto de “emoções básicas” adotado é composto pelas emoções: a) “felicidade” (*happiness*); b) “medo” (*fear*); c) “nojo” (*disgust*); d) “raiva” (*anger*); e) “surpresa” (*surprise*); e f) “tristeza” (*sadness*).

Uma breve definição de cada uma destas emoções é apresentada no Quadro 5.

QUADRO 5 - DEFINIÇÃO DAS “EMOÇÕES BÁSICAS” EMPREGADAS NESTE ESTUDO

Emoção	Definição
Felicidade (<i>Happiness</i>)	Conjunto de sentimentos que são apreciados e procurados pelo indivíduo. Diferente das demais emoções, esta não é de fácil compreensão (EKMAN, 2011, p.365).
Medo (<i>Fear</i>)	Resposta à ameaça de dano, quer seja físico ou psicológico. Pode ativar impulsos como “congelamento” e fuga (EKMAN, 2011, p.365).
Nojo (<i>Disgust</i>)	Repulsa pela visão, cheiro ou gosto de algo. Também pode se manifestar por pessoas cujas ações são revoltantes ou por ideias ofensivas (EKMAN, 2011, p.365).
Raiva (<i>Anger</i>)	Caracteriza-se como uma resposta instintiva à ameaça e/ou à frustração a objetivos e/ou a desejos (TAVRIS, 1989, p.24).
Surpresa (<i>Surprise</i>)	A mais curta das emoções, sendo uma resposta a um evento súbito e inesperado (EKMAN, 2011, p.365).
Tristeza (<i>Sadness</i>)	Refere-se ao modo como uma pessoa se sente e/ou age quando acredita que as coisas que deseja ou gosta são inalcançáveis ou estão perdidas (SHWEDER, 2004, p.87).

FONTE: Elaborado pelo autor (2019).

Optou-se pelas emoções listadas no Quadro 5 em virtude dos resultados obtidos no estudo conduzido por Ekman (2016), que constatou, junto à comunidade de pesquisadores do tema, uma alta concordância com relação ao emprego das emoções “raiva” (91,00%); “medo” (90,00%); “nojo” (86,00%); “tristeza” (80,00%); “felicidade” (76,00%). Para outras emoções - incluindo a emoção “surpresa” -, a taxa de aceitação variou entre 40,00% a 50,00% (EKMAN, 2016).

Após a definição sobre quais emoções utilizar, o primeiro passo para a construção da base de dados consistiu na identificação das músicas associadas a estas emoções na plataforma Last.FM, no período de 19/05/2019 a 26/05/2019. Adotou-se esta plataforma por conta de recomendações e exemplos de utilização desta em outros trabalhos de reconhecimento de emoções em músicas (ÇANO; MORISIO, 2017a, 2017b; POLLACCI et al., 2018; ALJANAKI; YANG; SOLEYMANI, 2018), além do fato de apresentar-se como um exemplo de folksonomia (JÄSCHKE

et al., 2007; YU et al., 2018), um dos objetos de estudo no campo da recuperação de informação (BOUADJENEK; HACID; BOUZEGHOUB, 2016).

Definiu-se empiricamente a coleta das 200 músicas com o maior destaque para as emoções definidas. Contudo, verificou-se que, para as emoções “nojo” e “surpresa”, não havia a quantidade de registros desejada, tendo apenas 12 registros associados à emoção “nojo” e 90 associados à “surpresa”. Para a emoção “nojo”, a baixa quantidade de registros pode ser explicada pelo fato desta ser uma emoção atípica para a expressão musical, sendo difícil encontrar representações musicais para esta emoção (ARGSTATTER, 2016). Desta forma, optou-se pela exclusão desta emoção da base de dados.

Antes da coleta das músicas identificadas, foi necessário adotar alguns procedimentos manuais para reduzir possíveis ruídos e distorções no tocante às classificações presentes na plataforma Last.fm. Os procedimentos adotados foram, a saber: a) identificar se a música estava disponível no *YouTube*; b) verificar se era um conteúdo musical, evitando a coleta de *podcasts*, gravações de voz, comerciais, etc...; c) remover registros cujo nome do artista apresentava a emoção buscada como, por exemplo: *Fear*; *Fear Factory*, etc...; e d) manter o primeiro registro encontrado, evitando duplicidade de registros.

Ressalta-se que, após a realização destes procedimentos, dos 90 registros da emoção “surpresa”, restaram 77 registros. Para as demais emoções, encontrou-se a quantidade desejada de 200 registros.

Na sequência, criou-se um total de cinco *playlists* (APÊNDICE A) para otimizar os processos de *download* dos registros, que foram realizados no período de 29/05/2019 a 01/06/2019, por meio de um *script* em Python, empregando a biblioteca *youtube-dl*. Por meio deste *script*, foi possível coletar apenas o áudio dos vídeos, em formato .mp3. O *script* elaborado encontra-se no Apêndice B.

Relativo aos procedimentos de pré-processamento dos arquivos, observando-se as diferentes durações para as músicas utilizadas, decidiu-se pela padronização da duração dos arquivos para 30 segundos (TZANETAKIS; COOK, 2002; LI; OGIHARA, 2003), sendo estes correspondentes ao 10º segundo até o 40º segundo de cada registro.

Além da padronização da duração dos arquivos, estabeleceu-se para todos os arquivos uma frequência de 22.050 Hz (TZANETAKIS; COOK, 2002; MCKAY,

2010) e uma taxa de bits de 128 kbps. Estes procedimentos foram realizados por meio da ferramenta Audacity, versão 2.1.0⁶.

Quanto aos descritores extraídos, elaborou-se um *script* em Python (APÊNDICE C) utilizando a biblioteca librosa (MCFEE et al., 2015), que permitiu extrair os 28 descritores diretamente dos arquivos .mp3.

Uma breve descrição destes descritores é apresentada a seguir:

- a) **Beats**: programação dinâmica para rastrear a batida do sinal (ELLIS, 2007);
- b) **Harmonic**: descritor para a extração do conteúdo harmônico de uma série temporal de áudio;
- c) **Mel-Frequency Cepstral Coefficients (MFCCs)**: consiste em um vetor de características tradicionalmente empregado em pesquisas de reconhecimento de fala (HAN et al. 2006; MCKAY, 2010);
- d) **Pitch-Shift**: descritor relacionado à variação (aumento/diminuição) do tom;
- e) **Spectral Centroid**: corresponde à noção do brilho do espectro. Representa, de certa forma, o quão “brilhante” é o espectro (TZANETAKIS; COOK, 2002; MCKAY, 2010). É obtido pela Equação 19 (MCKAY, 2010, p.134):

$$SC_t = \frac{\sum_{n=1}^N P_t[n] * n}{\sum_{n=1}^N P_t[n]} \quad (19)$$

- f) **Spectral Contrast**: reflete, aproximadamente, a distribuição dos componentes harmônicos e não harmônicos do espectro (JIANG et al., 2002);
- g) **Spectral Flatnes**: quantifica o quão próximo a distribuição espectral está de uma distribuição uniforme (GRAY; MARKEL, 1974; SCHMIDT; TURNBULL; KIM, 2010);
- h) **Spectral Roll-off**: representa a frequência na qual 85,00% da magnitude da distribuição está concentrada (TZANETAKIS; COOK, 2002; MCKAY, 2010).

⁶ Disponível em: < <https://www.audacityteam.org/>>. Acesso em: 26 jun. 2019.

É obtido pela Equação 20 (MCKAY, 2010, p.134):

$$\sum_{n=1}^{SR_t} P_t[n] = 0,85 \sum_{n=1}^N P_t[n] \quad (20)$$

- i) **Root Mean Square (RMS)**: representa a amplitude média quadrática de um sinal. É obtido por meio da Equação 21 (MCKAY, 2010, p.137):

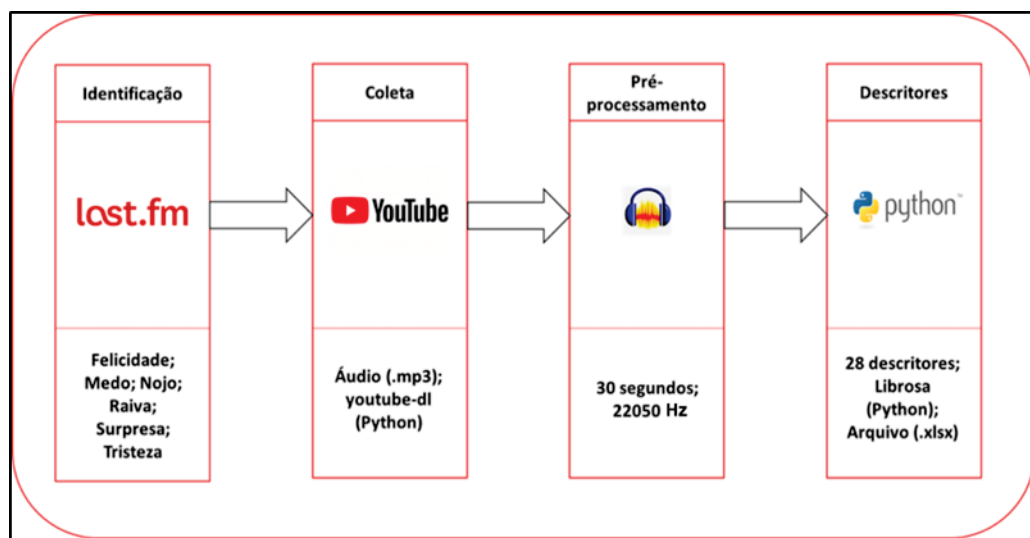
$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x[n]^2} \quad (21)$$

- j) **Tempo**: descritor destinado a estimar a quantidade de batimentos por minuto do sinal;
- k) **Zero-Crossing Rate (ZCR)**: indica quantas vezes o sinal alterna entre valores positivos e negativos, fornecendo uma medida do ruído do sinal (TZANETAKIS; COOK, 2002; MCKAY, 2010).
É calculado pela Equação 22 (TZANETAKIS; COOK, 2002, p.295).

$$Zt = \frac{1}{2} \sum_{n=1}^N |sign(x[n]) - sign(x[n-1])| \quad (22)$$

Os procedimentos adotados para a construção da base de dados estão sintetizados na Figura 13.

FIGURA 13 - SÍNTESE DOS PROCEDIMENTOS PARA A CONSTRUÇÃO DA BASE DE DADOS



FONTE: Elaborado pelo Autor (2019).

Todo o processo de extração foi realizado mediante o uso de uma janela de 512 amostras (TZANETAKIS; COOK, 2002; MCKAY, 2010), sem sobreposição. O descritor “Beats” foi construído utilizando a soma total de cada registro, enquanto, para o descritor “Tempo”, considerou-se o número total de batidas.

Com relação aos coeficientes do descritor “MFCCs”, extraiu-se os valores para a média e o desvio padrão dos 5 primeiros coeficientes (TZANETAKIS; COOK, 2002; SILLA JR.; KOERICH; KAESTNER, 2008). Por fim, para os demais descritores, considerou-se os valores para a média e o desvio padrão. As estatísticas descritivas da base de dados são apresentadas no Apêndice D.

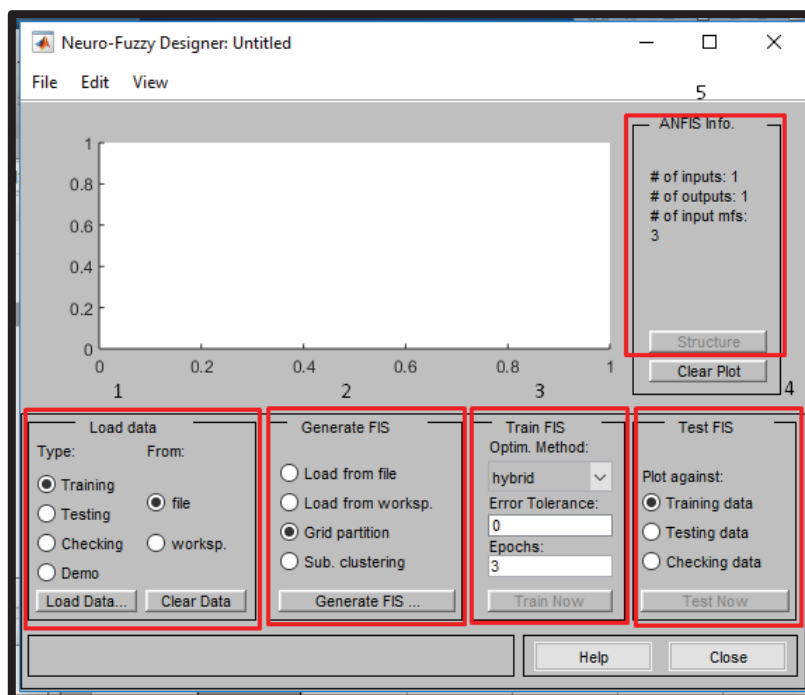
3.4 EXPERIMENTOS UTILIZANDO A ESTRUTURA ANFIS

Esleveu-se a estrutura ANFIS - bem como o *software* MATLAB® - devido à aplicação destes em trabalhos relacionados à aplicação de sistemas neuro-fuzzy (SALAHSHOOR; KORDESTANI; KHOSHRO, 2010; YAN; ZOU; WANG, 2010; MOTAMED; SETAYESHI; RABIEE, 2017; GHORBANZADEH et al., 2018; WANG et al., 2018) e pela existência de uma interface gráfica denominada *Neuro-Fuzzy Designer*⁷ que permite o treinamento de um modelo sem a necessidade do desenvolvimento de *scripts*.

⁷ Disponível em: <<https://www.mathworks.com/help/fuzzy/neurofuzzydesigner-app.html>>. Acesso em: 07 jul. 2019.

A ferramenta adotada é detalhada na Figura 14.

FIGURA 14 - INTERFACE GRÁFICA NEURO-FUZZY DESIGNER



FONTE: Elaborado pelo Autor (2019).

Observando-se a Figura 14, tem-se as seguintes opções:

- 1) Carregar os dados: treinamento, teste e validação;
- 2) Gerar o sistema de inferência *fuzzy*: permite a escolha dos métodos *grid partition* ou *subtractive clustering*;
- 3) Treinar o sistema de inferência *fuzzy*: é possível optar pelos métodos de otimização do tipo híbrido (*hybrid*) ou *backpropagation*; determinar o valor correspondente à tolerância permitida para o erro; e estabelecer o número de épocas para o treinamento;
- 4) Testar os resultados: gera um gráfico de comparação dos resultados com os dados de treinamento, teste e validação;
- 5) Verificar a estrutura do modelo gerado: número de entradas; número de funções de pertinência.

Antes do início dos experimentos com a estrutura ANFIS, realizou-se a normalização dos atributos da base de dados (TZANETAKIS; COOK, 2002; SILLA JR.; KOERICH; KAESTNER, 2008) por meio da Equação 23.

$$x = \frac{x_i - \text{mínimo}(x)}{\text{máximo}(x) - \text{mínimo}(x)} \quad (23)$$

Onde x_i representa o valor atual do descritor na posição i ; $\text{mínimo}(x)$ representa o valor mínimo do descritor; e $\text{máximo}(x)$ indica o valor máximo do descritor.

Tendo em vista que a estrutura ANFIS baseia-se em um sistema de inferência do tipo Sugeno (YAN; ZOU; WANG, 2010; MANOGARAN; VARADHARAJAN; PRIYAN, 2017; GHORBANZADEH et al., 2018), a mesma fornece apenas saídas em forma de uma constante ou uma saída linear (BURAGOHAİN; MAHANTA, 2008; YAN; ZOU; WANG, 2010). Posto isto, adotou-se valores numéricos para os valores nominais que representam as emoções empregadas.

A estratégia de atribuir valores numéricos para valores nominais é adotada em estudos em que o atributo alvo é nominal (SALAHSHOOR; KORDESTANI; KHOSHRO, 2010; YAN; ZOU; WANG, 2010; SUBASI, 2012; ZHANG et al., 2013) e emprega-se a estrutura ANFIS. Neste sentido, adotou-se como ponto de partida uma adaptação dos intervalos definidos por Yan, Zou e Wang (2010), uma vez que, não se encontrou trabalhos relacionados ao reconhecimento de emoções em músicas - ou reconhecimento de emoções - com intervalos pré-definidos.

Por conta da limitação ao se adaptar intervalos pertencentes a uma abordagem não condizente com o escopo deste trabalho, bem como a característica subjetiva e ambígua das próprias emoções, adotou-se quatro estratégias de classificação: a) cinco emoções; b) quatro emoções, desconsiderando a emoção surpresa; c) classificação considerando conjuntos de três emoções; e d) classificação binária.

Os intervalos adotados para os experimentos relacionados à primeira estratégia - cinco emoções - são listados no Quadro 6.

QUADRO 6 - INTERVALOS DEFINIDOS
(CINCO EMOÇÕES)

Emoção	Valor Alvo	Intervalo
Raiva (<i>Anger</i>)	1	$\geq 0; 1,5 <$
Medo (<i>Fear</i>)	2	$\geq 1,5; 2,5 <$
Felicidade (<i>Happiness</i>)	3	$\geq 2,5; 3,5 <$
Tristeza (<i>Sadness</i>)	4	$\geq 3,5; 4,5 <$
Surpresa (<i>Surprise</i>)	5	$\geq 4,5; 6,0 \leq$

FONTE: Elaborado pelo Autor (2019).

Com base nos intervalos listados no Quadro 6, por exemplo, caso o resultado de um registro seja igual a 1,8, o registro será classificado como “medo”. Por sua vez, um resultado igual a 3,56 será classificado como “tristeza”.

Por conta a diferença de registros relacionados à emoção “surpresa” - 77 registros -, elaborou-se um cenário sem esta emoção, adotando os seguintes intervalos para as emoções restantes (QUADRO 7).

QUADRO 7 - INTERVALOS DEFINIDOS
(QUATRO EMOÇÕES)

Emoção	Valor Alvo	Intervalo
Raiva (<i>Anger</i>)	1	$\geq 0; 1,5 <$
Medo (<i>Fear</i>)	2	$\geq 1,5; 2,5 <$
Felicidade (<i>Happiness</i>)	3	$\geq 2,5; 3,5 <$
Tristeza (<i>Sadness</i>)	4	$\geq 3,5; 4,5 \leq$

FONTE: Elaborado pelo Autor (2019).

Os intervalos presentes no Quadro 7 apresentam a mesma característica adotada para os intervalos definidos para as cinco emoções, ou seja, um registro igual a 1,8 será considerado como “medo”, e um resultado igual a 3,56 será classificado como “tristeza”.

A terceira estratégia empregada caracterizou-se em trabalhar com conjuntos compostos por três emoções cada. Diferente das estratégias para quatro e cinco emoções, nesta estratégia atribuiu-se um intervalo de 0,5 para cada emoção presente em um total de quatro conjuntos elaborados.

Os intervalos definidos para esta estratégia são apresentados no Quadro 8.

QUADRO 8 - INTERVALOS E CONJUNTOS (TRÊS EMOÇÕES)

Emoções	Valor Alvo	Intervalo
Raiva (<i>Anger</i>); Medo (<i>Fear</i>); Felicidade (<i>Happiness</i>)	0,25; 0,75; 1,25	$\geq 0; 0,5 <$ $\geq 0,5; 1,0 <$ $\geq 1,0; 1,5 \leq$
Raiva (<i>Anger</i>); Medo (<i>Fear</i>); Tristeza (<i>Sadness</i>)	0,25; 0,75; 1,25	$\geq 0; 0,5 <$ $\geq 0,5; 1,0 <$ $\geq 1,0; 1,5 \leq$
Medo (<i>Fear</i>); Felicidade (<i>Happiness</i>); Tristeza (<i>Sadness</i>)	0,25; 0,75; 1,25	$\geq 0; 0,5 <$ $\geq 0,5; 1,0 <$ $\geq 1,0; 1,5 \leq$
Raiva (<i>Anger</i>); Felicidade (<i>Happiness</i>); Tristeza (<i>Sadness</i>)	0,25; 0,75; 1,25	$\geq 0; 0,5 <$ $\geq 0,5; 1,0 <$ $\geq 1,0; 1,5 \leq$

FONTE: Elaborado pelo Autor (2019).

Por fim, a última estratégia adotada consistiu na classificação binária entre as emoções, estabelecendo seis conjuntos, cada um composto por duas emoções, representadas pelos valores de zero (0) e um (1) (QUADRO 9).

QUADRO 9 - INTERVALOS E CONJUNTOS (DUAS EMOÇÕES)

Emoções	Valor Alvo	Intervalo
Raiva (<i>Anger</i>) x Medo (<i>Fear</i>)	0;1	$\geq 0; 0,5 <$ $\geq 0,5; 1 \leq$
Raiva (<i>Anger</i>) x Felicidade (<i>Happiness</i>)	0;1	$\geq 0; 0,5 <$ $\geq 0,5; 1 \leq$
Raiva (<i>Anger</i>) x Tristeza (<i>Sadness</i>)	0;1	$\geq 0; 0,5 <$ $\geq 0,5; 1 \leq$
Medo (<i>Fear</i>) x Felicidade (<i>Happiness</i>)	0;1	$\geq 0; 0,5 <$ $\geq 0,5; 1 \leq$
Medo (<i>Fear</i>) x Tristeza (<i>Sadness</i>)	0;1	$\geq 0; 0,5 <$ $\geq 0,5; 1 \leq$
Felicidade (<i>Happiness</i>) x Tristeza (<i>Sadness</i>)	0;1	$\geq 0; 0,5 <$ $\geq 0,5; 1 \leq$

FONTE: Elaborado pelo Autor (2019).

Os termos apresentados em negrito no Quadro 9 representam a classe positiva (1), sendo esta obtida ao considera-se um *threshold* (CHAUDHARY; KOLHE; KAMAL, 2010; CHEN; MATTHEWS; TAVNER, 2013) em que, resultados superiores ou iguais a 0,50 são considerados como um (1).

No que concerne aos parâmetros adotados para os experimentos, empregou-se o método de inferência *grid partition* para os conjuntos com 3 ou 4 atributos, empregando as funções de pertinência dos tipos triangular, trapezoidal, sino e gaussiana.

Para os conjuntos com cinco ou mais atributos, o método *Subtractive clustering* foi utilizado, pois o mesmo é indicado para problemas com um número maior de atributos (KESHAVARZI et al., 2017). Para este método, ajustou-se os parâmetros da opção *Cluster Influence Range* (0,50; 0,45; 0,40 e 0,35) (KESHAVARZI et al., 2017). Para ambos os métodos de inferência empregou-se os métodos de otimização híbrido e *backpropagation*, bem como variou-se o número de épocas entre 50, 100 e 200 épocas.

A lista dos parâmetros considerados é apresentada no Quadro 10.

QUADRO 10 - PARÂMETROS ADOTADOS PARA OS EXPERIMENTOS COM A ESTRUTURA ANFIS

Método de inferência	Método de otimização	Saída considerada	Parâmetros utilizados	Funções de pertinência (número)	Quantidade de épocas
<i>Grid partition</i> (conjuntos com 3 a 4 atributos)	Híbrido; <i>Backpropagation</i>	Constante	Funções de pertinência (Triangular; Trapezoidal; Sino e Gaussiana)	2; 3 e 4	50; 100 e 200
<i>Sub. clustering</i> conjuntos com mais de 4 atributos)	Híbrido; <i>Backpropagation</i>	Linear	<i>Cluster Influence Range</i> (0,50; 0,45; 0,40 e 0,35)	-	50; 100 e 200

FONTE: Elaborado pelo Autor (2019).

No que diz respeito à quantidade de instâncias de treinamento, reservou-se aleatoriamente 80,00% dos registros; enquanto para o conjunto de teste, utilizou-se 20,00%. Todos os experimentos foram desenvolvidos com o auxílio do *software* MATLAB®, versão '9.6.0.1135713 (R2019a).

Após a apresentação dos procedimentos adotados para a elaboração dos experimentos utilizando a estrutura ANFIS, a seguir descreve-se a etapa de seleção de atributos.

3.5 SELEÇÃO DE ATRIBUTOS

Devido à base de dados elaborada conter 28 atributos, verificou-se uma limitação ao se utilizar a estrutura ANFIS, posto que, estudos indicam a necessidade em se adotar um número reduzido de entradas (JANG, 1996; GÜNERI; ERTAY; YÜCEL, 2011; NADERLOO et al., 2012) devido à complexidade computacional provocada pela relação “número de entradas x quantidade de regras” (JANG, 1996; GÜNERI; ERTAY; YÜCEL, 2011; NADERLOO et al., 2012).

Neste sentido, por exemplo, um problema com seis entradas e três funções de pertinência para cada entrada resultaria em um total de 726 regras *fuzzy* (3^6). Por conta desta característica, com a atual base de dados, adotando duas funções de pertinência, o sistema teria um total de 268.435.456 regras (2^{28}).

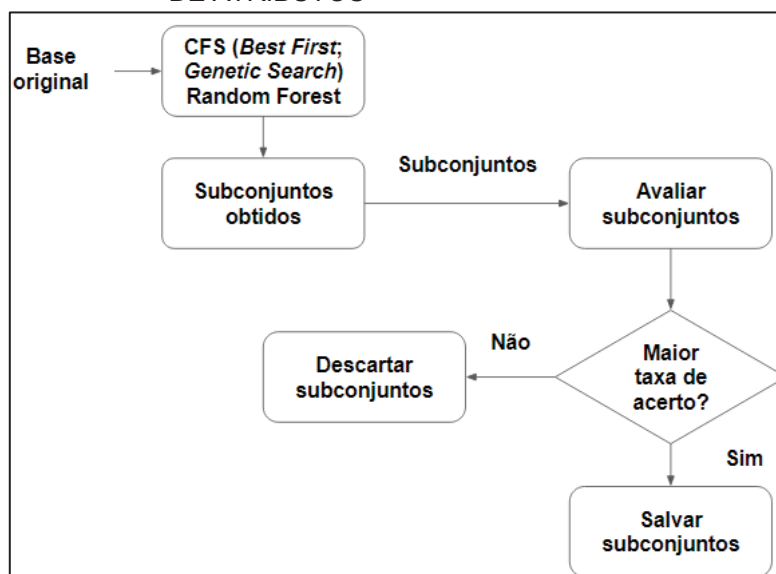
Para contornar esta limitação, adotou-se uma estratégia de seleção de atributos (KARABULUT; ÖZEL; IBRIKCI, 2012; CHANDRASHEKAR; SAHIN, 2014), que consistiu na combinação do método de seleção *Correlation-based Feature* (CFS) (HALL, 1999) com os algoritmos de busca *Best First* (DECHTER; PEARL, 1985) e *Genetic Search* (GOLDBERG; HOLLAND, 1988), somados ao algoritmo *Random Forest* (BREIMAN, 2001). Todos os experimentos de seleção de atributos foram realizados com o *software* Weka 3.8⁸, mantendo-se todos os parâmetros dos algoritmos como *default*, alterando-se apenas o algoritmo de busca (*Best First* ou *Genetic Search*).

Escolheu-se o método CFS por este ser uma das principais abordagens para a seleção de atributos (MIREEI; AMINI-POZVEH; NAZERI, 2017), tendo como princípio a escolha de atributos altamente correlacionados com a classe e não correlacionados entre si (HALL, 1999; MIREEI; AMINI-POZVEH; NAZERI, 2017). Por fim, optou-se pela combinação deste método com os demais elementos com base na aplicação destes em outros estudos, em que se adotou a etapa de seleção de atributos (CHAUDHARY; KOLHE; KAMAL, 2016; XU et al., 2017; GEORGANOS et al., 2018).

O processo de seleção de atributos adotado é resumido na Figura 15.

⁸ Disponível em: < <https://www.cs.waikato.ac.nz/ml/weka/downloading.html>>. Acesso em: 20 set. 2019.

FIGURA 15 - RESUMO DO PROCESSO DE SELEÇÃO DE ATRIBUTOS



FONTE: Elaborado pelo Autor (2019).

Neste estudo, realizou-se a seleção de atributos para cada cenário idealizado (cinco emoções; quatro emoções; três emoções e duas emoções), considerando os mesmos intervalos descritos na subseção 3.4. Como critério de escolha dos atributos, elegeu-se o conjunto de atributos que obteve a maior taxa de acerto.

Dos conjuntos obtidos (APÊNDICE E), o conjunto com o menor número de elementos apresentou três atributos (*Contrast_mean*; *Contrast_std* e *ZCR_mean*) e diz respeito às emoções “medo”; “felicidade” e “tristeza”. Por sua vez, os cenários envolvendo as emoções “raiva”; “medo” e “felicidade” e “felicidade e tristeza” apresentaram o maior número de atributos, com sete atributos cada. Os atributos *Tempo*; *Pitch_mean*; *Harmonic_std*; *Centroid_std*; *Contrast_mean*; *Flatness_mean* e *ZCR_mean* relacionados ao primeiro, e os atributos *Harmonic_mean*; *Harmonic_std*; *MFCC_std_5*; *Centroid_mean*; *Contrast_mean*; *Contrast_std* e *ZCR_mean* representando o segundo conjunto.

Finalizada a seção referente aos encaminhamentos metodológicos do estudo, a próxima seção apresenta a análise e a discussão dos resultados.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Nesta seção são elencados os resultados deste estudo. Apresenta-se e discute-se todos os resultados, bem como todos os cenários e estruturas desenvolvidas para cada sistema neuro-*fuzzy* aplicado. Por fim, estabelece-se a comparação dos resultados do estudo frente a outros métodos e arquiteturas de classificação.

4.1 RESULTADOS OBTIDOS PARA CINCO E QUATRO EMOÇÕES

O primeiro experimento consistiu no emprego da estrutura ANFIS considerando as cinco emoções definidas neste estudo. Para isto, realizou-se um total de 68 cenários de classificação.

Ressalta-se que, ao empregar-se o método de otimização *backpropagation*, não foi possível realizar o treinamento para as seguintes combinações: a) quatro funções de pertinência do tipo triangular e 200 épocas; b) três funções de pertinência do tipo trapezoidal e 200 épocas; c) quatro funções de pertinência do tipo trapezoidal, com 100 e 200 épocas, respectivamente. Para estes cenários, houve um alerta do próprio *software* Matlab com relação ao uso de memória. Posto isto, todos os percentuais relacionados às taxas de acerto e os cenários realizados são apresentados no Apêndice F.

Analisando-se os cenários do Apêndice F, nota-se que a maior taxa de acerto para o conjunto de teste correspondeu a 26,70% - 47 instâncias classificadas corretamente -, obtida ao se utilizar o método de otimização híbrido, com quatro funções de pertinência do tipo triangular. Para os dados de treinamento, esta combinação obteve 34,24% de acerto (240 registros). Neste cenário, a taxa de acerto manteve-se constante independentemente do número de épocas adotado. A estrutura deste sistema é listada no Quadro 11.

QUADRO 11 - ESTRUTURA DO SISTEMA NEURO-FUZZY (CINCO EMOÇÕES)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(4-1)	Nós	551
Funções de pertinência (entrada)	4-4-4-4	Parâmetros lineares	256
Funções de pertinência (saída)	256	Parâmetros não-lineares	48
Método (e)	"prod"	Total de parâmetros	304
Método (ou)	"probor"	Instâncias de treinamento	701
Método (implicação)	"prod"	Instâncias de teste	176
Método (agregação)	"sum"	Regras <i>fuzzy</i>	256
Método (defuzzificação)	"wtaver"		

FONTE: Elaborado pelo Autor (2019).

Com relação à matriz de confusão com os registros classificados corretamente e incorretamente neste cenário para o conjunto de treinamento, esta é representada na Figura 16.

FIGURA 16 - MATRIZ DE CONFUSÃO CINCO EMOÇÕES (TREINAMENTO)

Emoção	Raiva	Medo	Felicidade	Tristeza	Surpresa	Total
Raiva	35	77	55	1	0	168
Medo	7	48	95	2	0	152
Felicidade	1	38	121	6	0	166
Tristeza	0	2	121	30	0	153
Surpresa	1	13	35	7	6	62
Total	44	178	427	46	6	701

FONTE: Elaborado pelo Autor (2019).

Verifica-se na matriz de confusão (FIGURA 16) que a emoção com o melhor desempenho em termos de classificação foi a emoção “felicidade”, cuja taxa de acerto foi de 72,89% (121/166). A emoção com a menor taxa de instâncias classificadas corretamente foi a emoção “surpresa”, com apenas 9,68% (6/62). As demais emoções apresentaram as seguintes taxas de acerto: “medo”, 31,58% (48/152); “raiva”, 20,98 (35/168); e “tristeza”, 19,61% (30/153). Para as instâncias de teste, a matriz de confusão é representada pela Figura 17.

FIGURA 17 - MATRIZ DE CONFUSÃO CINCO
EMOÇÕES (TESTE)

Emoção	Raiva	Medo	Felicidade	Tristeza	Surpresa	Total
Raiva	7	10	12	1	2	32
Medo	0	8	29	8	3	48
Felicidade	1	8	23	0	2	34
Tristeza	1	1	34	9	2	47
Surpresa	2	4	9	0	0	15
Total	11	31	107	18	9	176

FONTE: Elaborado pelo Autor (2019).

Observa-se nesta matriz de confusão (FIGURA 17) que a emoção “felicidade” apresentou o melhor desempenho de classificação, com 67,65% (23/34) de registros classificados corretamente. Por sua vez, a emoção “surpresa” teve todos os seus registros classificados incorretamente, sendo que, 13,33% (2/15) foram classificados como “raiva”; 26,67% (4/15) como “medo”; e 60,00% (9/15) como “felicidade”.

As demais emoções ficaram abaixo dos 25,00% de acerto. Por fim, as respectivas funções de pertinência obtidas para o melhor cenário de classificação considerando as cinco emoções são representadas no Apêndice G.

Tendo em vista a diferença de registros pertencentes à emoção “surpresa” na base de dados - 77 registros, contra 200 das demais emoções -, e o baixo desempenho de classificação desta ao se considerar as cinco emoções, optou-se pela remoção desta emoção do conjunto de dados. Desta forma, 24 cenários de classificação foram realizados, considerando-se apenas as emoções “raiva”, “medo”, “felicidade” e “tristeza. Os percentuais relacionados às taxas de acerto e os cenários realizados para esta estratégia são apresentados no Apêndice H.

Com base nos cenários do Apêndice H, verifica-se que a maior taxa de acerto para o conjunto de teste correspondeu a 28,57%, representando 46 registros corretamente classificados. Este resultado foi obtido por meio da combinação do método de otimização híbrido, ajustando o parâmetro *Cluster Influence Range* para 0.35. Neste cenário, obteve-se 32,71% de acerto (209 registros) para os dados de treinamento. A estrutura deste sistema é listada no Quadro 12.

QUADRO 12 - ESTRUTURA DO SISTEMA NEURO-FUZZY (QUATRO EMOÇÕES)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(5-1)	Nós	104
Funções de pertinência (entrada)	8-8-8-8-8	Parâmetros lineares	48
Funções de pertinência (saída)	8	Parâmetros não-lineares	80
Método (e)	"prod"	Total de parâmetros	128
Método (ou)	"probor"	Instâncias de treinamento	639
Método (implicação)	"prod"	Instâncias de teste	161
Método (agregação)	"sum"	Regras <i>fuzzy</i>	8
Método (defuzzificação)	"wtaver"		

FONTE: Elaborado pelo Autor (2019).

No que diz respeito à matriz de confusão deste cenário para o conjunto de treinamento, esta é apresentada na Figura 18.

FIGURA 18 - MATRIZ DE CONFUSÃO QUATRO EMOÇÕES (TREINAMENTO)

Emoção	Raiva	Medo	Felicidade	Tristeza	Total
Raiva	45	80	38	0	163
Medo	11	59	84	2	156
Felicidade	1	66	97	1	165
Tristeza	0	19	128	8	155
Total	57	224	347	11	639

FONTE: Elaborado pelo Autor (2019).

Verifica-se na matriz de confusão (FIGURA 18) que a emoção “felicidade” apresentou 58,79% (97/165) de registros classificados corretamente. A emoção com a menor taxa de instâncias classificadas corretamente foi a emoção “tristeza”, com 5,16% (8/155). As emoções “medo” e “raiva” apresentaram uma taxa de acerto de 37,82% (59/156) e 27,61% (45/163), respectivamente. Para as instâncias de teste, a matriz de confusão é representada pela Figura 19.

FIGURA 19 - MATRIZ DE CONFUSÃO QUATRO EMOÇÕES (TESTE)

Emoção	Raiva	Medo	Felicidade	Tristeza	Total
Raiva	13	14	10	0	37
Medo	4	10	29	1	44
Felicidade	0	18	17	0	35
Tristeza	0	4	35	6	45
Total	17	46	91	7	161

FONTE: Elaborado pelo Autor (2019).

Constata-se na matriz de confusão do conjunto de teste (FIGURA 19) que a emoção “felicidade” teve o melhor desempenho de classificação, apresentando um total de 48,57% (17/35) de registros classificados corretamente. Entretanto, a maioria das instâncias desta emoção - 51,43% (18/35) - foi classificada erroneamente como “medo”.

Por sua vez, a emoção “medo” também apresentou maior percentual dos seus registros classificados como outra emoção, tendo 65,91% (29/44) dos registros classificados como “felicidade”, contra 22,73% (10/44) classificados corretamente. A emoção “tristeza” apresentou o pior desempenho, com 13,33% (6/45) de registros classificados corretamente.

Atenta-se para o fato de que, 77,78% dos registros originalmente pertencentes à “tristeza” foram classificados como “felicidade”. Ademais, obteve-se 35,14% (13/37) de acerto para emoção “raiva”, com os demais registros desta classificados como “medo” (37,84% (14/37)) e “felicidade” (27,03% (10/37)). Finalmente, as respectivas funções de pertinência obtidas para o melhor cenário de classificação considerando as cinco emoções são representadas no Apêndice I.

4.2 RESULTADOS ATINGIDOS PARA TRÊS EMOÇÕES

Com base nos valores obtidos para os experimentos considerando cinco e quatro emoções, constatou-se que os resultados para estas estratégias ficaram abaixo dos 50,00% de acerto. Além disso, emoções como “medo” e “tristeza” apresentarem a maioria dos registros classificados como outra emoção. Desta forma, desenvolveu-se uma nova estratégia empregando apenas três emoções de cada vez,

totalizando quatro novos conjuntos, a saber: a) “raiva”; “medo” e “felicidade”; b) “raiva”; “medo” e “tristeza”; c) “raiva”; “felicidade” e “tristeza”; e d) “medo”; “felicidade” e “tristeza”.

O primeiro conjunto submetido à estrutura ANFIS foi o conjunto composto pelas emoções “raiva”; “medo” e “felicidade”. Para este, 24 cenários de classificação foram realizados. Os respectivos percentuais de acerto e os cenários realizados para esta estratégia são apresentados no Apêndice J.

Ao se analisar os cenários presentes no Apêndice J, percebe-se que a maior taxa de acerto para o conjunto de teste correspondeu a 40,00% (48/120) de acerto, obtido ao se utilizar o método de otimização *backpropagation*, com 200 épocas de treinamento e 0,45 para o parâmetro *Cluster Influence Range*.

Para as instâncias de treinamento, este cenário apresentou uma taxa de acerto de 43,96%, representando 211 registros corretamente classificados. A estrutura deste sistema é listada no Quadro 13.

QUADRO 13 - ESTRUTURA DO SISTEMA NEURO-FUZZY (RAIVA; MEDO; FELICIDADE)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(7-1)	Nós	106
Funções de pertinência (entrada)	7-7-7-7-7-7-7	Parâmetros lineares	48
Funções de pertinência (saída)	7	Parâmetros não-lineares	84
Método (e)	“prod”	Total de parâmetros	132
Método (ou)	“probor”	Instâncias de treinamento	480
Método (implicação)	“prod”	Instâncias de teste	120
Método (agregação)	“sum”	Regras <i>fuzzy</i>	7
Método (defuzzificação)	“wtaver”		

FONTE: Elaborado pelo Autor (2019).

A respectiva matriz de confusão deste cenário para o conjunto de treinamento é apresentada na Figura 20.

FIGURA 20 - MATRIZ DE CONFUSÃO ("RAIVA"; "MEDO" E "FELICIDADE" - TREINAMENTO)

Emoção	Raiva	Medo	Felicidade	Total
Raiva	51	112	0	163
Medo	17	136	8	161
Felicidade	4	128	24	156
Total	72	376	32	480

FONTE: Elaborado pelo Autor (2019).

Verifica-se na matriz de confusão (FIGURA 20) que a emoção "medo" apresentou um percentual de 84,47% (136/161) de registros classificados corretamente. A emoção "felicidade", com 15,38% (24/156) apresentou o pior desempenho. Por fim, a emoção "raiva" teve 51 registros corretamente classificados (31,29%). Para as instâncias de teste, a matriz de confusão é representada pela Figura 21.

FIGURA 21- MATRIZ DE CONFUSÃO ("RAIVA"; "MEDO" E "FELICIDADE" - TESTE)

Emoção	Raiva	Medo	Felicidade	Total
Raiva	7	25	5	37
Medo	0	30	9	39
Felicidade	1	32	11	44
Total	8	87	25	120

FONTE: Elaborado pelo Autor (2019).

Constate-se na matriz de confusão do conjunto de teste (FIGURA 21) que a emoção "medo" teve o melhor desempenho de classificação, apresentando um total de 76,92% (30/39) de registros classificados corretamente. Com relação aos registros incorretos, nove registros (23,08%) desta emoção foram classificados como "felicidade".

Os registros pertencentes à emoção "felicidade" foram classificados corretamente em 25,00% (11/44), enquanto 72,73% (32/44) foram incorretamente classificados como "medo", e apenas um registro de "felicidade" foi classificado como "raiva".

A emoção "raiva" apresentou uma taxa de acerto de 18,92% (7/37), com 67,57% (25/37) dos registros classificados como "medo", e 13,51% (5/37) como

“felicidade”. As funções de pertinência elaboradas para o melhor cenário de classificação considerando as cinco emoções são representadas no Apêndice K.

O próximo conjunto submetido à estrutura ANFIS foi composto pelas emoções “raiva”, “medo” e “tristeza”. Para estas emoções, 68 cenários foram desenhados, conforme exposto no Apêndice L. Ressalta-se que, dos cenários do Apêndice L, quatro combinações apresentaram erros relacionados ao uso de memória pelo *software Matlab*, sendo estes: a) quatro funções de pertinência do tipo triangular e 200 épocas; b) três funções de pertinência do tipo trapezoidal e 200 épocas; c) quatro funções de pertinência do tipo trapezoidal, com 100 e 200 épocas, respectivamente.

Com base nos cenários do Apêndice L, obteve-se como a maior taxa de acerto para o conjunto de teste o valor de 57,50% - 69 registros corretamente classificados. Este valor foi obtido mediante a combinação do método de otimização híbrido, com três funções de pertinência do tipo triangular e 100 épocas de treinamento. Para as instâncias de treinamento, a mesma combinação proporcionou 56,67% de acerto - 272 registros. A estrutura deste sistema é listada no Quadro 14.

QUADRO 14 - ESTRUTURA DO SISTEMA NEURO-FUZZY
(RAIVA; MEDO; TRISTEZA)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(4-1)	Nós	193
Funções de pertinência (entrada)	3-3-3-3	Parâmetros lineares	81
Funções de pertinência (saída)	81	Parâmetros não-lineares	36
Método (e)	"prod"	Total de parâmetros	117
Método (ou)	"probor"	Instâncias de treinamento	480
Método (implicação)	"prod"	Instâncias de teste	120
Método (agregação)	"sum"	Regras <i>fuzzy</i>	81
Método (defuzzificação)	"wtaver"		

FONTE: Elaborado pelo Autor (2019).

A matriz de confusão para o conjunto de treinamento é apresentada na Figura 22.

FIGURA 22 - MATRIZ DE CONFUSÃO (“RAIVA”; “MEDO”
E “TRISTEZA” - TREINAMENTO)

Emoção	Raiva	Medo	Tristeza	Total
Raiva	90	68	5	163
Medo	31	111	19	161
Tristeza	2	83	71	156
Total	123	262	95	480

FONTE: Elaborado pelo Autor (2019).

Observa-se na matriz de confusão (FIGURA 22) que a única emoção com menos de 50,00% de acerto correspondeu à emoção “tristeza”, cuja taxa de acerto consistiu em 45,51% (71/156). Para esta emoção, 53,21% (83/156) dos registros de foram incorretamente classificados como “medo”. Por sua vez, 68,94% (111/161) dos registros pertencentes à emoção “medo” foram classificados corretamente, enquanto 19,25% (31/161) foram equivocadamente classificados como “raiva”, e 11,80% (19/161) como “tristeza”.

Referente à emoção “raiva”, 55,21% (90/163) dos seus registros foram classificados corretamente, contra 41,72% (68/163) classificados como “medo” e 3,07% (5/163) como “tristeza”. No que diz respeito aos dados de teste, a matriz de confusão é representada pela Figura 23.

FIGURA 23 - MATRIZ DE CONFUSÃO (“RAIVA”; “MEDO” E “TRISTEZA” - TESTE)

Emoção	Raiva	Medo	Tristeza	Total
Raiva	25	9	3	37
Medo	3	26	10	39
Tristeza	3	23	18	44
Total	31	58	31	120

FONTE: Elaborado pelo Autor (2019).

Contate-se na Figura 23 que a emoção “raiva” apresentou o melhor desempenho de classificação, com um total de 67,57% (25/37) de registros classificados corretamente. Com relação aos erros para esta emoção, 24,32% (9/37) das instâncias foram classificadas como “medo” e 8,11% (3/37) como “tristeza”.

No que diz respeito à emoção “medo”, 66,67% (26/39) dos seus registros foram classificados de forma correta, com 25,64% (10/39) erroneamente classificados como “tristeza” e 7,69% (3/39) como “raiva”. Finalmente, a única emoção que apresentou a maioria dos seus registros classificados equivocadamente foi a emoção “tristeza”, uma vez que, 52,27% (23/44) das instâncias estão como “medo”, contra 40,91% (18/44) registros corretos. As respectivas funções de pertinência obtidas para o melhor cenário de classificação para estas emoções são representadas no Apêndice M.

O terceiro conjunto composto por três emoções englobou as emoções “raiva”, “felicidade” e “tristeza”. Para estas emoções, 71 cenários foram desenvolvidos (APÊNDICE N). Dos cenários do Apêndice N, apenas ao se utilizar quatro funções de

pertinência do tipo trapezoidal e 200 épocas obteve-se erro relacionado ao uso de memória pelo *software Matlab*.

Analisando-se os cenários elaborados (APÊNDICE N), identifica-se como melhor cenário de classificação a combinação do método de otimização híbrido, com quatro funções de pertinência do tipo gaussiana e 50 épocas de treinamento. Neste cenário, taxa de registros corretamente classificados para o conjunto de teste foi igual 65,83% - 79 registros corretamente classificados. Para os dados de treino, a mesma combinação classificou corretamente 68,13% dos registros - 327 registros. A estrutura deste sistema é listada no Quadro 15.

QUADRO 15 - ESTRUTURA DO SISTEMA NEURO-FUZZY
(RAIVA; FELICIDADE; TRISTEZA)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(4-1)	Nós	551
Funções de pertinência (entrada)	4-4-4-4	Parâmetros lineares	256
Funções de pertinência (saída)	256	Parâmetros não-lineares	32
Método (e)	"prod"	Total de parâmetros	288
Método (ou)	"probor"	Instâncias de treinamento	480
Método (implicação)	"prod"	Instâncias de teste	120
Método (agregação)	"sum"	Regras <i>fuzzy</i>	256
Método (defuzzificação)	"wtaver"		

FONTE: Elaborado pelo Autor (2019).

A matriz de confusão para os dados de treinamento é apresentada na Figura 24.

FIGURA 24 - MATRIZ DE CONFUSÃO ("RAIVA"; "FELICIDADE"
E "TRISTEZA" – TREINAMENTO)

Emoção	Raiva	Felicidade	Tristeza	Total
Raiva	103	59	1	163
Felicidade	18	132	11	161
Tristeza	1	63	92	156
Total	122	254	104	480

FONTE: Elaborado pelo Autor (2019).

Observa-se nesta matriz de confusão (FIGURA 24) que todas as emoções do conjunto de treino apresentaram taxas de acerto superiores aos 50,00%, sendo, respectivamente, 63,19% (103/163) de acerto para os registros de "raiva"; 81,99%(132/161) para as instâncias de "felicidade"; e 58,97% (92/156) para a emoção "tristeza". Em termos de classificações incorretas, a emoção "raiva" teve 36,20% (59/163) dos registros classificados como "felicidade", enquanto 40,38% (63/156)

pertencentes à emoção “tristeza” foram equivocadamente considerados como “felicidade”. No que concerne aos dados de teste, a matriz de confusão destes é representada pela Figura 25.

FIGURA 25 - MATRIZ DE CONFUSÃO (“RAIVA”; “FELICIDADE” E “TRISTEZA” - TESTE)

Emoção	Raiva	Felicidade	Tristeza	Total
Raiva	22	11	4	37
Felicidade	1	34	4	39
Tristeza	2	19	23	44
Total	25	64	31	120

FONTE: Elaborado pelo Autor (2019).

Percebe-se na Figura 25 que, assim como os resultados para o conjunto de treino, a taxa de acerto para as três emoções foi superior a 50,00%. Das três emoções, a emoção “felicidade” apresentou 87,18% (34/39) dos seus registros classificados corretamente, contra 10,26% (22/37) classificados como “tristeza”.

Dos registros originais da emoção “raiva”, 59,46% (22/37) foram classificados de forma correta, enquanto 29,73% (11/37) classificados como “felicidade”, e 10,81% (4/37) como “tristeza”. Para a emoção “tristeza”, o total de instâncias corretas foi de 52,27% (23/44), contra 43,18% (19/44) classificados como “felicidade”, e 4,55% (2/44) classificados como “raiva”. As funções de pertinência para este conjunto de emoções são representadas no Apêndice O.

O último conjunto da estratégia composta por três emoções diz respeito às emoções “medo”, “felicidade” e “tristeza”. Ao total, 71 cenários foram testados (APÊNDICE P). Dos cenários elaborados (APÊNDICE P), somente ao se empregar quatro funções de pertinência do tipo trapezoidal e 200 épocas obteve-se erro relacionado ao uso de memória pelo *software Matlab*.

A maior taxa de registros corretamente classificados para o conjunto de teste corresponde a 55 registros, que representam 45,83% dos registros. Obteve-se este valor por meio do uso de quatro funções de pertinência do tipo trapezoidal, com 200 épocas de treinamento e com o método de otimização *backpropagation*.

Para o conjunto de treinamento, 41,88% (201/480) das instâncias foram corretamente classificadas. A estrutura deste sistema é listada no Quadro 16.

QUADRO 16 - ESTRUTURA DO SISTEMA NEURO-FUZZY
(MEDO; FELICIDADE; TRISTEZA)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(3-1)	Nós	34
Funções de pertinência (entrada)	2-2-2	Parâmetros lineares	8
Funções de pertinência (saída)	8	Parâmetros não-lineares	24
Método (e)	"prod"	Total de parâmetros	32
Método (ou)	"probor"	Instâncias de treinamento	480
Método (implicação)	"prod"	Instâncias de teste	120
Método (agregação)	"sum"	Regras fuzzy	8
Método (defuzzificação)	"wtaver"		

FONTE: Elaborado pelo Autor (2019).

Por sua vez, a matriz de confusão para os dados de treinamento é apresentada na Figura 26.

FIGURA 26 - MATRIZ DE CONFUSÃO ("MEDO"; "FELICIDADE"
E "TRISTEZA" –TREINAMENTO)

Emoção	Medo	Felicidade	Tristeza	Total
Medo	24	133	6	163
Felicidade	9	149	3	161
Tristeza	0	128	28	156
Total	33	410	37	480

FONTE: Elaborado pelo Autor (2019).

A partir da interpretação da Figura 26, tem-se que das três emoções utilizadas neste conjunto, apenas a taxa de acerto para a emoção "felicidade" superou os 50,00%, totalizando 149 registros corretamente classificados (92,55%). As demais emoções apresentaram, menos de 25,00% de instâncias classificadas de forma correta, sendo 14,72% (24/163) de registros relacionados à emoção "medo", e 17,95% (28/156) para as instâncias originais da emoção "tristeza". Com relação aos dados de teste, a matriz de confusão para estes registros é representada na Figura 27.

FIGURA 27 - MATRIZ DE CONFUSÃO ("MEDO"; "FELICIDADE"
E "TRISTEZA" - TESTE)

Emoção	Medo	Felicidade	Tristeza	Total
Medo	8	26	3	37
Felicidade	0	39	0	39
Tristeza	1	35	8	44
Total	9	100	11	120

FONTE: Elaborado pelo Autor (2019).

Repara-se na Figura 27 um percentual de 100,00% (39/39) de acerto para a emoção “felicidade”. Para as emoções “medo” e “tristeza”, as taxas de acerto foram de 21,62% (8/37) e 18,18% (8/44), respectivamente. Neste cenário, estas duas emoções apresentam mais de 70,00% dos seus registros incorretamente associados à emoção “felicidade”, sendo que este percentual consistiu em 70,27% (26/37) para a emoção “medo”, e 79,55% (35/44) para a emoção “tristeza”. Para estas emoções, as funções de pertinência geradas são apresentadas no Apêndice Q.

4.3 RESULTADOS ALCANÇADOS PARA DUAS EMOÇÕES

A última estratégia de classificação adotada neste estudo consistiu na divisão das emoções em pares, construindo, para isso, seis conjuntos, a saber: a) “raiva” e “medo”; b) “raiva” e felicidade”; c) “raiva” e tristeza”; d) “medo” e “felicidade”; e) “medo” e “tristeza”; e f) “felicidade” e “tristeza”.

Para as emoções “raiva” e “medo”, elaborou-se um total de 24 cenários de classificação, empregando o método de inferência *Subtractive clustering* (APÊNDICE R). Dentre os cenários elaborados, a maior taxa de acerto para o conjunto de teste consistiu em 72,50% (58/80), obtida ao se utilizar 0,50 para o parâmetro *Cluster Influence Range*, somado ao uso do método de otimização híbrido. A estrutura do sistema neuro-fuzzy responsável por este cenário é apresentada no Quadro 17.

QUADRO 17 - ESTRUTURA DO SISTEMA NEURO-FUZZY (RAIVA E MEDO)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(6-1)	Nós	79
Funções de pertinência (entrada)	5-5-5-5-5-5	Parâmetros lineares	35
Funções de pertinência (saída)	5	Parâmetros não-lineares	60
Método (e)	“prod”	Total de parâmetros	95
Método (ou)	“probor”	Instâncias de treinamento	320
Método (implicação)	“prod”	Instâncias de teste	80
Método (agregação)	“sum”	Regras fuzzy	5
Método (defuzzificação)	“wtaver”		

Fonte: Elaborado pelo autor (2019).

Para o conjunto de treinamento, 73,13% (243/320) dos dados foram corretamente classificados. A matriz de confusão com o desempenho para estes dados é retratada na Figura 28.

FIGURA 28 - MATRIZ DE CONFUSÃO
("RAIVA" E "MEDO" - TREINAMENTO)

Emoção	Medo	Raiva	Total
Medo	120	46	166
Raiva	40	114	154
Total	160	160	320

Fonte: Elaborado pelo autor (2019).

Mediante a análise da matriz de confusão obtida (Figura 28), tem-se 72,29% (120/166) de acerto para a emoção "medo" e 74,03% (114/154) para a emoção "raiva". Por sua vez, para as instâncias de teste (Figura 29), as taxas de acerto foram de 61,78% (21/34) para a emoção "medo" e de 80,43% (37/46) para os registros de "raiva".

FIGURA 29 - MATRIZ DE CONFUSÃO ("RAIVA" E
"MEDO" - TESTE)

Emoção	Medo	Raiva	Total
Medo	21	13	34
Raiva	9	37	46
Total	30	50	80

Fonte: Elaborado pelo autor (2019).

As funções de pertinência obtidas para este cenário são apresentadas no Apêndice S.

Para a classificação envolvendo as emoções "raiva" e "felicidade", novamente 24 cenários foram elaborados (APÊNDICE T), dos quais a maior taxa de acerto obtida foi de 71,25% para dois cenários: a) algoritmo de otimização *backpropagation* com 50 épocas de treinamento e 0,35 para o parâmetro *cluster influence range*; b) *backpropagation* com 200 épocas de treinamento e 0,45 para o parâmetro *cluster influence range*.

Neste caso, elegeu-se o cenário "a" como o melhor por conta da menor diferença entre o valor obtido para o conjunto de treino e o conjunto de teste, bem como o menor número de épocas de treinamento. A estrutura do sistema neuro-fuzzy eleito é apresentada no Quadro 18.

QUADRO 18 - ESTRUTURA DO SISTEMA NEURO-FUZZY (RAIVA E FELICIDADE)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(6-1)	Nós	191
Funções de pertinência (entrada)	13-13-13-13-13-13	Parâmetros lineares	91
Funções de pertinência (saída)	13	Parâmetros não-lineares	156
Método (e)	"prod"	Total de parâmetros	247
Método (ou)	"probor"	Instâncias de treinamento	320
Método (implicação)	"prod"	Instâncias de teste	80
Método (agregação)	"sum"	Regras <i>fuzzy</i>	13
Método (defuzzificação)	"wtaver"		

Fonte: Elaborado pelo autor (2019).

Referente aos dados de treinamento, 77,81% (249/320) dos dados foram corretamente classificados. A matriz de confusão deste desempenho é retratada na Figura 30.

FIGURA 30 - MATRIZ DE CONFUSÃO ("RAIVA" E "FELICIDADE" - TREINAMENTO)

Emoção	Felicidade	Raiva	Total
Felicidade	122	42	164
Raiva	29	127	156
Total	151	169	320

Fonte: Elaborado pelo autor (2019).

Nesta matriz de confusão (Figura 30), observa-se uma taxa de acerto de 74,39% (122/164) para a emoção "felicidade". A emoção "raiva", por sua vez, apresentou 81,41% (127/156) de instâncias classificadas corretamente. Para as instâncias de teste (Figura 31), a emoção "felicidade" apresentou um percentual de acerto de 69,44% (25/36); enquanto a emoção "raiva" teve 72,73% (32/44) de registros corretamente classificados.

FIGURA 31 - MATRIZ DE CONFUSÃO ("RAIVA" E "FELICIDADE" (TESTE))

Emoção	Felicidade	Raiva	Total
Felicidade	25	11	36
Raiva	12	32	44
Total	37	43	80

Fonte: Elaborado pelo autor (2019).

Em relação às funções de pertinência para estas emoções, estas são representadas no Apêndice U.

Empregando-se as emoções "raiva" e "tristeza" para a classificação por meio da estrutura ANFIS, obteve-se 68 cenários de classificação (APÊNDICE V), dos quais, o maior valor em termos de acerto para as instâncias de teste foi de 88,75% (71/80) ao se utilizar o método de otimização *backpropagation* com duas funções de pertinência do tipo trapezoidal e 200 épocas de treinamento. A respectiva arquitetura deste sistema neuro-*fuzzy* é apresentada no Quadro 19.

QUADRO 19 - ESTRUTURA DO SISTEMA NEURO-FUZZY (RAIVA E TRISTEZA)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(4-1)	Nós	55
Funções de pertinência (entrada)	2-2-2-2	Parâmetros lineares	16
Funções de pertinência (saída)	16	Parâmetros não-lineares	32
Método (e)	"prod"	Total de parâmetros	48
Método (ou)	"probor"	Instâncias de treinamento	320
Método (implicação)	"prod"	Instâncias de teste	80
Método (agregação)	"sum"	Regras <i>fuzzy</i>	16
Método (defuzzificação)	"wtaver"		

Fonte: Elaborado pelo autor (2019).

Para aos dados de treinamento, 81,88% (262/320) das instâncias foram corretamente identificadas, conforme exposto na Figura 32.

FIGURA 32 - MATRIZ DE CONFUSÃO ("RAIVA" E "TRISTEZA" - TREINAMENTO)

Emoção	Raiva	Tristeza	Total
Raiva	116	38	154
Tristeza	20	146	166
Total	136	184	320

Fonte: Elaborado pelo autor (2019).

Analisando-se a Figura 32, nota-se uma taxa de acerto de 75,32% (116/154) para as instâncias da emoção "raiva". Para a emoção "tristeza", 87,95% (146/166) das instâncias foram corretamente classificadas. Para o conjunto de teste (Figura 33), a emoção "raiva" apresentou 84,78% (39/46) de acerto; enquanto a emoção "tristeza" apresentou um percentual de 94,12% (32/34) de registros corretamente classificados.

FIGURA 33 - MATRIZ DE CONFUSÃO ("RAIVA" E "TRISTEZA" (TESTE))

Emoção	Raiva	Tristeza	Total
Raiva	39	7	46
Tristeza	2	32	34
Total	41	39	80

Fonte: Elaborado pelo autor (2019).

As funções de pertinência para estas emoções são representadas no Apêndice W.

No que corresponde às emoções "medo" e "felicidade", um total de 24 cenários de classificação foi realizado (APÊNDICE X). Dos cenários propostos, o melhor desempenho eleito para o conjunto de teste apresentou uma taxa de acerto de 57,50% (46/80) de registros corretos. A respectiva estrutura deste cenário é apresentada no Quadro 20.

QUADRO 20 - ESTRUTURA DO SISTEMA NEURO-FUZZY (MEDO E FELICIDADE)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(5-1)	Nós	80
Funções de pertinência (entrada)	6-6-6-6-6	Parâmetros lineares	36
Funções de pertinência (saída)	6	Parâmetros não-lineares	60
Método (e)	"prod"	Total de parâmetros	96
Método (ou)	"probor"	Instâncias de treinamento	320
Método (implicação)	"prod"	Instâncias de teste	80
Método (agregação)	"sum"	Regras <i>fuzzy</i>	6
Método (defuzzificação)	"wtaver"		

Fonte: Elaborado pelo autor (2019).

Para os dados de treinamento, este valor correspondeu a 70,63% (226/320) de instâncias corretamente classificadas. A matriz de confusão deste valor é ilustrada na Figura 34.

FIGURA 34 - MATRIZ DE CONFUSÃO ("MEDO" E "FELICIDADE" - TREINAMENTO)

Emoção	Felicidade	Medo	Total
Felicidade	130	36	166
Medo	58	96	154
Total	188	132	320

FONTE: Elaborado pelo Autor (2019).

Na matriz de confusão acima (Figura 34), verifica-se uma taxa de acerto de 78,31% (130/166) para as instâncias da emoção "felicidade". Para a emoção "medo", 62,34% (96/154) das instâncias foram corretamente classificadas. Para os dados de teste (Figura 35), a emoção "felicidade" obteve um total de 76,47% (26/34) de acerto; enquanto a emoção "medo" apresentou 43,48% (20/46) de registros corretamente classificados.

FIGURA 35 - MATRIZ DE CONFUSÃO ("MEDO" E "FELICIDADE" - TESTE)

Emoção	Felicidade	Medo	Total
Felicidade	26	8	34
Medo	26	20	46
Total	52	28	80

FONTE: Elaborado pelo Autor (2019).

As funções de pertinência para estas emoções são representadas no Apêndice Y.

Utilizando-se as emoções "medo" e "tristeza", um total de 72 cenários de classificação foram realizados (Apêndice Z), dos quais, o melhor cenário apresentou um percentual de 76,25% (61/80) de registros de teste corretamente classificados. A respectiva estrutura deste cenário é apresentada no Quadro 21.

QUADRO 21 - ESTRUTURA DO SISTEMA NEURO-FUZZY (MEDO E TRISTEZA)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(3-1)	Nós	34
Funções de pertinência (entrada)	2-2-2	Parâmetros lineares	8
Funções de pertinência (saída)	8	Parâmetros não-lineares	18
Método (e)	"prod"	Total de parâmetros	26
Método (ou)	"probor"	Instâncias de treinamento	320
Método (implicação)	"prod"	Instâncias de teste	80
Método (agregação)	"sum"	Regras <i>fuzzy</i>	8
Método (defuzzificação)	"wtaver"		

FONTE: Elaborado pelo Autor (2019).

Para aos dados de treinamento, 65,00% (208/320) das instâncias foram corretamente identificadas, conforme exposto na Figura 36.

FIGURA 36 - MATRIZ DE CONFUSÃO ("MEDO" E "TRISTEZA" (TREINAMENTO))

Emoção	Tristeza	Medo	Total
Tristeza	126	40	166
Medo	72	82	154
Total	198	122	320

FONTE: Elaborado pelo Autor (2019).

Na matriz de confusão acima (Figura 36), nota-se uma taxa de acerto de 75,90% (126/166) para as instâncias da emoção “tristeza”. Para a emoção “medo”, 53,25% (82/154) das instâncias foram corretamente classificadas. Para os dados de teste (Figura 37), a emoção “tristeza” obteve um total de 76,47% (26/34) de acerto; enquanto a emoção “medo” apresentou um percentual de 76,09% (35/46) de registros corretamente classificados.

FIGURA 37 - MATRIZ DE CONFUSÃO (“MEDO” E “TRISTEZA” -TESTE)

Emoção	Tristeza	Medo	Total
Tristeza	26	8	34
Medo	11	35	46
Total	37	43	80

FONTE: Elaborado pelo Autor (2019).

As funções de pertinência para estas emoções são representadas no Apêndice AA.

O último conjunto submetido à estrutura ANFIS diz respeito às emoções “felicidade” e “tristeza”, para o qual 24 cenários foram elaborados (APÊNDICE BB). O melhor desempenho para registrado para dados de teste apresentou taxa de acerto de 81,25% (65/80). A respectiva estrutura deste cenário é listada no Quadro 22.

QUADRO 22 - ESTRUTURA DO SISTEMA NEURO-FUZZY (FELICIDADE E TRISTEZA)

Estrutura	Valores	Modelo	Valores
Entradas-Saída	(7-1)	Nós	138
Funções de pertinência (entrada)	8-8-8-8-8-8-8	Parâmetros lineares	64
Funções de pertinência (saída)	8	Parâmetros não-lineares	112
Método (e)	“prod”	Total de parâmetros	176
Método (ou)	“probor”	Instâncias de treinamento	320
Método (implicação)	“prod”	Instâncias de teste	80
Método (agregação)	“sum”	Regras fuzzy	8
Método (defuzzificação)	“wtaver”		

FONTE: Elaborado pelo Autor (2019).

Para aos dados de treinamento, 83,75% (268/320) das instâncias foram corretamente identificadas, conforme exposto na Figura 38.

FIGURA 38 - MATRIZ DE CONFUSÃO ("FELICIDADE" E "TRISTEZA" - TREINAMENTO)

Emoção	Tristeza	Felicidade	Total
Tristeza	143	23	166
Felicidade	29	125	154
Total	172	148	320

FONTE: Elaborado pelo Autor (2019).

Com base na Figura 38, verifica-se uma taxa de acerto de 86,14% (143/166) para as instâncias da emoção "tristeza", e 81,17% (125/154) de instâncias corretamente classificadas para a emoção "felicidade". Nos dados de teste (Figura 39), a emoção "tristeza" obteve um total de 85,29% (29/34) de acerto; enquanto a emoção "felicidade" apresentou 78,26% (36/46) de registros classificados de maneira correta.

FIGURA 39 - MATRIZ DE CONFUSÃO ("FELICIDADE" E "TRISTEZA" - TESTE)

Emoção	Tristeza	Felicidade	Total
Tristeza	29	5	34
Felicidade	10	36	46
Total	39	41	80

FONTE: Elaborado pelo Autor (2019).

As funções de pertinência para estas emoções são representadas no Apêndice CC.

Finalizada as discussões acerca dos resultados deste estudo, a seguir apresenta-se uma comparação destes com outras heurísticas, a fim de verificar o desempenho dos diferentes sistemas *neuro-fuzzy* desenvolvidos.

4.4 COMPARAÇÃO DOS RESULTADOS

Diante dos resultados obtidos, bem como dos diferentes cenários realizados, identificou-se que das quatro estratégias de classificação - cinco, quatro, três e duas emoções - adotadas neste estudo, os dois piores desempenhos correspondem aos experimentos considerando cinco e quatro emoções. A taxa de acerto para as

instâncias de testes destes cenários correspondeu a 26,70% ao se considerar cinco emoções, e 28,57% para quatro emoções.

Para os conjuntos compostos por três emoções cada, constatou-se uma melhora nos resultados, com dois dos quatro conjuntos superando os 50,00% de registros corretamente classificados: a) o conjunto composto pelas emoções “raiva”, “felicidade” e “tristeza”, cuja taxa de acerto foi de 65,83%; e b) “raiva”, “medo” e “tristeza”, com 57,50%.

Entretanto, notou-se que, quando os conjuntos apresentavam as emoções “medo” e “felicidade”, a taxa de acerto não ultrapassou os 50,00% de instâncias classificadas corretamente. Para as emoções “raiva”, “medo” e “felicidade”, este percentual foi de 40,00% de acerto; para as emoções “medo”, “felicidade” e “tristeza”, a taxa de acerto foi de 45,83%.

Considerando apenas duas emoções, todos os cenários apresentaram mais de 70%00 de registros classificados corretamente, com exceção ao cenário envolvendo as emoções “medo” e “felicidade”, cuja taxa de acerto ficou em 57,50%. Dois cenários apresentaram mais de 80,00% de registros classificados, sendo estes: a) “raiva” e “tristeza”, com 88,75% de acerto; e b) “alegria” e “tristeza”, com taxa de acerto de 81,25%.

Com o objetivo de avaliar os resultados deste estudo com os resultados obtidos com outros métodos, elaborou-se uma comparação considerando os seguintes algoritmos e arquiteturas: a) J48 - implementação em Java do algoritmo C4.5 (QUINLAN, 2014); b) *Multilayer Perceptron* (GARDNER; DORLING, 1998); e c) Naive Bayes (LEWIS, 1998). Para estes métodos, considerou-se os mesmos atributos utilizados nos experimentos envolvendo a estrutura ANFIS. Além disso, utilizou-se o atributo meta “emoções” como nominal.

A comparação entre os resultados é elencada no Quadro 23.

QUADRO 23 - COMPARAÇÃO DOS RESULTADOS

Conjunto	ANFIS	<i>Random Forest</i> (seleção de atributos)	J48	<i>Multilayer Perceptron</i>	<i>Naive Bayes</i>
5 emoções	26,70%	37,71%	42,86%	38,86%	40,57%
4 emoções	28,57%	39,38%	40,63%	43,75%	38,12%
Raiva; Medo e Felicidade	40,00%	40,83%	46,67%	54,17%	50,83%
Raiva; Medo e Tristeza	57,50%	51,67%	50,83%	52,50%	55,00%
Raiva; Felicidade e Tristeza	65,83%	62,50%	61,67%	65,00%	57,50%
Medo; Felicidade e Tristeza	45,83%	45,00%	41,67%	50,00%	48,33%
Raiva e Medo	72,50%	67,50%	71,25%	72,50%	58,75%
Raiva e Felicidade	71,25%	62,50%	61,25%	72,50%	57,50%
Raiva e Tristeza	88,75%	85,00%	76,25%	88,75%	82,50%
Medo e Felicidade	57,50%	52,50%	58,75%	61,25%	68,75%
Medo e Tristeza	67,50%	67,50%	63,75%	67,50%	66,25%
Felicidade e Tristeza	81,25%	70,00%	71,25%	72,25%	71,25%

FONTE: Elaborado pelo Autor (2019).

Observa-se no Quadro 23 que a estrutura ANFIS apresentou o melhor desempenho em seis cenários, ficando atrás apenas do método *Multilayer Perceptron*, que obteve melhor desempenho em sete cenários. Entretanto, ressalta-se que, para este, as emoções foram classificadas de forma original, ou seja, sem a criação e adaptação de intervalos numéricos.

Comparando os resultados da estrutura ANFIS com a estratégia elaborada para a seleção de atributos, verifica-se que a estrutura ANFIS somente teve desempenho inferior a esta ao se considerar a classificação com cinco (37,71% - 26,70%) e quatro emoções (39,38% - 28,57%), bem como ao se testar o conjunto composto pelas emoções “raiva”, “medo” e “felicidade” (40,83% - 40,00%)

Percebe-se que, mesmo ao se considerar as emoções como um atributo nominal, os resultados obtidos com o uso da estrutura ANFIS superaram os resultados proporcionados por métodos como os algoritmos J48 e *Naive Bayes*. Em comparação com o algoritmo J48, este apresentou resultados superiores aos obtidos pela estrutura ANFIS em quatro cenários: a) cinco emoções; b) quatro emoções; c) “raiva”, “medo” e “felicidade”; e d) “medo” e “felicidade”. Por sua vez, o algoritmo Naive Bayes superou

a estrutura ANFIS em cinco cenários: a) cinco emoções; b) quatro emoções; c) “raiva”, “medo” e “felicidade”; d) “medo”, felicidade” e “tristeza”; e e) “medo” e “felicidade”.

Finalizada a seção destinada à análise e discussão dos resultados, a última seção deste estudo apresenta as considerações finais deste.

5 CONSIDERAÇÕES FINAIS

Esta pesquisa apresentou como objetivo geral reconhecer emoções em músicas por meio da aplicação de sistemas *neuro-fuzzy*. Para isto, três objetivos específicos foram definidos como forma de atingir o objetivo geral proposto.

Em relação à identificação da taxonomia de emoções utilizada - objetivo específico “a” -, adotou-se o conjunto de emoções conhecido como “emoções básicas”, devido à “aceitação” desta abordagem pelos pesquisadores do tema. Apesar desta “concordância” sobre quais termos empregar, os trabalhos de reconhecimento de emoções em músicas optam pelos modelos dimensionais, principalmente empregando os graus de valência e excitação.

Para o objetivo específico “b - construção de uma base de dados composta por um conjunto de descritores” criou-se uma base de dados composta por 877 registros e 28 atributos, que representam as músicas mais populares da plataforma Last.FM para as emoções básicas “raiva”, “medo”, “felicidade”, “tristeza” e “surpresa”.

Na criação desta base, escolheu-se a plataforma Last.FM, pois esta é um exemplo de folksonomia, um dos objetos de estudo no campo de estudo da recuperação de informação. Além disso, a construção desta base visou contornar a dificuldade em se obter base de dados públicas para problemas de reconhecimento de emoções em músicas. Em virtude desta barreira, almeja-se disponibilizar esta para que outros pesquisadores realizem novos estudos.

Em termos de resultados, julga-se os resultados deste estudo como promissores, principalmente pelos obtidos ao se considerar os cenários envolvendo três e duas emoções. Com relação ao desempenho, estes cenários apresentaram em determinados experimentos resultados superiores aos obtidos por métodos tradicionais de classificação - objetivo específico “c” -, mesmo considerando para estes o atributo “emoções” como nominal, ou seja, sem o viés proporcionado pela adaptação ou pela criação de intervalos numéricos.

No que se refere à aplicação dos sistemas *neuro-fuzzy* recorreu-se às pesquisas que aplicaram esta abordagem e, desta forma, constatou-se a estrutura ANFIS como o método mais empregado. Portanto, adotou-se esta estrutura na construção de um conjunto de experimentos, considerando diferentes cenários de classificação e combinações de parâmetros.

Contudo, identificou-se limitações no uso da estrutura ANFIS, como a necessidade de se reduzir o número de atributos de entradas, em razão da complexidade computacional existente na relação exponencial “número de atributos x número de regras”. A saída proporcionada pela arquitetura também representou uma limitação, pois apenas saídas de forma constante ou linear são permitidas. Deste modo, foi necessário transformar o atributo “emoções” em intervalos numéricos.

Visando contornar a limitação relativa ao número de atributos, este adotou a estratégia de seleção de atributos, composta pelo método de seleção de atributos CFS, combinado com os algoritmos de busca Best First e Genetic Search, e o algoritmo *Random Forest*. Com estes elementos, obteve-se conjuntos específicos para cada estratégia de classificação, variando-se o número de atributos entre três e sete por conjuntos. Esta estratégia pode ser replicada em pesquisas futuras em que exista a necessidade de se reduzir o número de atributos.

Relativo às emoções, as emoções “raiva”, “felicidade” e “tristeza” apresentaram as maiores taxas de acerto ao se classificar três emoções (65,83%). Para as classificações binárias, cinco dos seis cenários ultrapassaram os 70,00% de instâncias classificadas corretamente. Por outro lado, percebeu-se desempenho inferior nos cenários ao se considerar as emoções “medo” e “felicidade” no mesmo conjunto; tais emoções demonstraram uma tendência de instâncias classificadas incorretamente entre si, indicando que há elementos de distinção não contemplados somente pelo áudio das canções.

Quanto ao tema deste estudo, o reconhecimento de emoções em músicas apresenta-se como um “desafio de pesquisa” devidos aos elementos subjetivos e ambíguos presentes nas emoções. Trata-se de um campo de pesquisa que recebe cada vez mais atenção de pesquisadores, motivado pelo grande acesso à música na era da internet, pelas possibilidades de aplicações dos resultados e por conta dos metadados tradicionais já não serem suficientes para a recuperação de informação.

Apesar da relação “música-emoção” ser um elemento de estudo em diferentes áreas do conhecimento, verificou-se que o reconhecimento de emoções como o “nojo” ainda é uma “dificuldade”, dado que não é comum o desenvolvimento de músicas visando provocar esta emoção. Este desafio refletiu-se na etapa de identificação das músicas utilizadas neste estudo, de forma que apenas 12 registros estavam associados a esta emoção.

Por fim, com base no conteúdo deste estudo, identifica-se potencial na aplicação dos sistemas *neuro-fuzzy* como abordagem para o reconhecimento de emoções em músicas, mediante os resultados obtidos e a forma como os sistemas *neuro-fuzzy* são projetados para problemas que apresentam incertezas e subjetividades. A capacidade de aprendizagem e a representação do conhecimento presentes nos sistemas *neuro-fuzzy* são um diferencial na aplicação deste tipo de método e seu uso deve ser aprimorado em novos estudos.

Em relação aos trabalhos futuros, elenca-se a possibilidade de se considerar uma abordagem multimodal para o reconhecimento de emoções em músicas, com descritores relacionados às letras das canções e às progressões de acordes, por exemplo, a julgar por aplicações em outros estudos com temática semelhante.

Neste sentido, abre-se a necessidade de se construir uma base de dados multimodal composta por estes elementos. Além disto, a extração destes pode ser realizada com base em amostras temporais com duração e intervalos diferentes dos considerados neste estudo.

Em virtude de uma das limitações deste estudo consistir na falta de uma escala numérica - requisito para o uso da estrutura ANFIS - que representasse as emoções básicas empregadas, sugere-se a criação de uma escala para representar estas emoções.

Como forma de validar estas sugestões, recomenda-se a construção de um painel de especialistas para discussão e validação dos descritores utilizados e das emoções - escalas - estabelecidas para compor a base de dados. Para a validação dos resultados, indica-se a comparação frente a uma amostra, cujo papel seria o de classificar as emoções da base de dados conforme a sua percepção.

REFERÊNCIAS

ABE, D.; ARAI, M.; ITOKAWA, M. Music-evoked emotions in schizophrenia. **Schizophrenia Research**, v. 185, p.144-147, jul. 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0920996416305874>>. Acesso em: 14 out. 2018.

AHMED, S. S. et al. Effect of fuzzy partitioning in Crohn's disease classification: a neuro-fuzzy-based approach. **Medical & Biological Engineering & Computing**, v. 55, n. 1, p. 101-115, jan. 2017. Disponível em: <<https://link.springer.com/article/10.1007/s11517-016-1508-7>>. Acesso em: 07 abr. 2019.

AKKURT, S.; TAYFUR, G.; CAN, S. Fuzzy logic model for the prediction of cement compressive strength. **Cement and Concrete Research**, v. 34, n. 8, p. 1429-1433, ago. 2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0008884604000444>>. Acesso em 22 set. 2019.

ALJANAKI, A.; WIERING, F.; VELTKAMP, R. C. Studying emotion induced by music through a crowdsourcing game. **Information Processing & Management**, v. 52, n. 1, p.115-128, jan. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306457315000424>>. Acesso em: 05 ago. 2018.

ALJANAKI, A.; YANG, Y.; SOLEYMANI, M. Developing a benchmark for emotional analysis of music. **Plos One**, v. 12, n. 3, p.1-22, mar. 2017. Disponível em: <<http://journals.plos.org/plosone/article?id=10.1371/journal.pone.0173392>>. Acesso em: 04 ago. 2018.

AL-JARRAH, O.; ABU-QDAIS, H. Municipal solid waste landfill siting using intelligent system. **Waste Management**, v. 26, n. 3, p. 299-306, 2006. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0956053X05001200>>. Acesso em: 05 mar. 2019.

AN, Y.; SUN, S.; WANG, S. Naive Bayes classifiers for music emotion classification based on lyrics. In: 2017 IEEE/ACIS 16TH INTERNATIONAL CONFERENCE ON COMPUTER AND INFORMATION SCIENCE (ICIS), 16., 2017, Wuhan. **Proceedings...** . Wuhan: IEEE, 2017. p. 635 - 638. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/7960070>>. Acesso em: 24 mar. 2019.

ARGSTATTER, H. Perception of basic emotions in music: Culture-specific or multicultural?. **Psychology of Music**, v. 44, n. 4, p. 674-690, 2016. Disponível em: <<https://journals.sagepub.com/doi/full/10.1177/0305735615589214>>. Acesso em: 08 jun. 2019.

ATSALAKIS, G. S.; PROTOPAPADAKIS, E. E.; VALAVANIS, K. P. Stock trend forecasting in turbulent market periods using neuro-fuzzy systems. **Operational Research**, v. 16, n. 2, p.245-269, set. 2015. Disponível em:

<<https://link.springer.com/article/10.1007/s12351-015-0197-6>>. Acesso em: 06 abr. 2019.

BAI, J. et al. Music emotions recognition by cognitive classification methodologies. In: 2017 IEEE 16th International Conference on Cognitive Informatics & Cognitive Computing (ICCI* CC), 16., 2017, Oxford. **Proceedings...** . Oxford: IEEE, 2017. p.121-129. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8109740>>. Acesso em: 20 abr. 2019.

BALAL, E.; CHEU, R. L. Comparative evaluation of fuzzy inference system, support vector machine and multilayer feed-forward neural network in making discretionary lane changing decisions. **Neural Network World**, v. 28, n. 4, p. 361-378, ago. 2018. Disponível em: <<https://search.proquest.com/docview/2102344444>>. Acesso em: 04 mar. 2019.

BALABANOVA, I. et al. Classification of teletraffic service devices by κ -NN, ANFIS and ANN classifiers. In: 2016 IEEE INTERNATIONAL BLACK SEA CONFERENCE ON COMMUNICATIONS AND NETWORKING (BLACKSEACOM), 4., 2016, Varna. **Proceedings...** . Varna: IEEE, 2016. p. 1 - 5. Disponível em: <<https://ieeexplore.ieee.org/document/7901585>>. Acesso em: 11 out. 2019.

BAKKER, I. et al. Pleasure, arousal, dominance: Mehrabian and Russell revisited. **Current Psychology**, v. 33, n. 3, p. 405-421, set. 2014. Disponível em: <<https://link.springer.com/article/10.1007/s12144-014-9219-4>>. Acesso em: 30 dez. 2018.

BARRETT, L. F. Psychological construction: The darwinian approach to the science of emotion. **Emotion Review**, v.5, n.4, p. 379-389, out. 2013. Disponível em: <<https://journals.sagepub.com/doi/10.1177/1754073913489753>>. Acesso em: 25 dez. 2018.

BARRETT, L. F.; WAGER, Tor D. The structure of emotion: Evidence from neuroimaging studies. **Current Directions in Psychological Science**, v. 15, n. 2, p. 79-83, abr. 2006. Disponível em: <<https://journals.sagepub.com/doi/abs/10.1111/j.0963-7214.2006.00411.x>>. Acesso em: 30 dez. 2018.

BARTHET, M.; FAZEKAS, G.; SANDLER, M. Multidisciplinary perspectives on music emotion recognition: implications for content and context-based models. In: 9TH INTERNATIONAL SYMPOSIUM ON COMPUTER MUSIC MODELLING AND RETRIEVAL, 9., 2012, Londres. **Proceedings...** . Londres: CMMR, 2012. p. 492 - 507. Disponível em: <<https://pdfs.semanticscholar.org/8fde/ffbf8d1fa688d74db882a1d8c7ebc596534b.pdf>>. Acesso em: 11 ago. 2018.

BELFI, A. et al. Musical anhedonia after focal brain damage. **Neuropsychologia**, v. 97, p. 29-37, mar. 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0028393217300362?via%3Dihub>>. Acesso em: 01 jan. 2019.

BĚLOHLÁVEK, R.; DAUBEN, J. W.; KLIR, G. J. **Fuzzy logic and mathematics: a historical perspective**. Nova Iorque: Oxford University Press, 2017.

BEVERIDGE, S.; KNOX, D. Popular music and the role of vocal melody in perceived emotion. **Psychology of Music**, v. 46, n. 3, p.411-423, 30 jun. 2017. Disponível em: <<https://journals.sagepub.com/doi/abs/10.1177/0305735617713834>>. Acesso em: 05 jan. 2019.

BIANCHI, R. E. **Extração de conhecimento simbólico em técnicas de aprendizado de máquina caixa-preta por similaridade de rankings**. 2008. 106 f. Tese (Doutorado) - Curso de Ciência da Computação e Matemática Computacional, Usp- São Carlos, São Carlos, 2008. Disponível em: <+-.>. Acesso em: 06 out. 2019.

BOBYR, M. V.; MILOSTNAYA, N. A.; KULABUHOV, S. A. A method of defuzzification based on the approach of areas' ratio. **Applied Soft Computing**, v. 59, p. 19-32, out. 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494617303034>>. Acesso em: 10 mar. 2019.

BOUADJENEK, M. R.; HACID, H.; BOUZEGHOUB, M. Social networks and information retrieval, how are they converging? A survey, a taxonomy and an analysis of social information retrieval approaches and platforms. **Information Systems**, v. 56, p.1-18, mar. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S030643791500160X>>. Acesso em: 11 jun. 2019.

BRADT, J. et al. The impact of music therapy versus music medicine on psychological outcomes and pain in cancer patients: a mixed methods study. **Supportive Care in Cancer**, v. 23, n. 5, p.1261-1271, 17 out. 2014. Disponível em: <<https://link.springer.com/article/10.1007/s00520-014-2478-7>>. Acesso em: 14 out. 2018.

BRATTICO, E. It's sad but I like it: The neural dissociation between musical emotions and liking in experts and laypersons. **Frontiers in Human Neuroscience**, v. 9, p.1-21, jan. 2016. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fnhum.2015.00676/full>>. Acesso em: 01 jan. 2019.

BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, out. 2001. Disponível em: <<https://link.springer.com/article/10.1023/A:1010933404324>>. Acesso em: 17 set. 2019.

BUI, D. T. et al. Landslide susceptibility mapping at Hoa Binh province (Vietnam) using an adaptive neuro-fuzzy inference system and GIS. **Computers & Geosciences**, v. 45, p. 199-211, 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0098300411003888>>. Acesso em: 14 abr. 2019.

BURAGOHAIN, M.; MAHANTA, C. A novel approach for ANFIS modelling based on full factorial design. **Applied Soft Computing**, v. 8, n. 1, p.609-625, jan. 2008.

Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S1568494607000464>>. Acesso em: 07 jul. 2019.

BUSTINCE, H. et al. A Historical Account of Types of Fuzzy Sets and Their Relationships. **IEEE Transactions on Fuzzy Systems**, v. 24, n. 1, p.179-194, fev. 2016. Disponível em: <<https://ieeexplore.ieee.org/document/7145399>>. Acesso em: 13 jan. 2019.

CABANAC, M. What is emotion? **Behavioural Processes**, v. 60, n. 2, p. 69-83, nov.-dez. 2002. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0376635702000785>>. Acesso em: 23 dez. 2018.

ÇANO, E.; MORISIO, M. Crowdsourcing emotions in music domain. **International Journal of Artificial Intelligence & Applications**, v. 8, n. 4, p. 25-40, 2017a. Disponível em: <<http://aircconline.com/ijaia/V8N4/8417ijaia03.pdf>>. Acesso em: 26 maio 2019.

ÇANO, E.; MORISIO, M. Music mood dataset creation based on Last. fm tags. In: 4TH INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND APPLICATIONS (AIAP-2017), 4., 2017b, Viena. **Proceedings...** . Viena: AIAP, 2017b. p. 1 - 13. Disponível em: <<https://iris.polito.it/retrieve/handle/11583/2669975/154238/ErionCanoMoodyLyrics2.pdf>>. Acesso em: 08 jun. 2019.

CASEY, M.a. et al. Content-based music information retrieval: current directions and future challenges. **Proceedings of the IEEE**, v. 96, n. 4, p.668-696, abr. 2008. Disponível em: <<https://ieeexplore-ieee-org.ez22.periodicos.capes.gov.br/document/4472077>>. Acesso em: 08 dez. 2018.

CELEGHIN, A. et al. Basic emotions in human neuroscience: Neuroimaging and beyond. **Frontiers in Psychology**, n. 8, p. 1-13, ago. 2017. Disponível: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5573709/>>. Acesso em: 24 dez. 2018.

CERVANTES, J. et al. Takagi–Sugeno dynamic neuro-fuzzy controller of uncertain nonlinear systems. **IEEE Transactions on Fuzzy Systems**, v. 25, n. 6, p. 1601-1615, 2017. Disponível em: <<https://ieeexplore.ieee.org/document/7574365>>. Acesso em: 07 abr. 2019.

CHATTOPADHYAY, S. A neuro-fuzzy approach for the diagnosis of depression. **Applied Computing and Informatics**, v. 13, n. 1, p. 10-18, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2210832714000027>>. Acesso em: 07 abr. 2019.

CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. **Computers & Electrical Engineering**, v. 40, n. 1, p. 16-28, jan. 2014. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0045790613003066>>. Acesso em: 17 set. 2019.

CHAUDHARY, A.; KOLHE, S.; KAMAL, R. An improved random forest classifier for multi-class classification. **Information Processing in Agriculture**, v. 3, n. 4, p. 215-222, dez. 2016. Disponível em:

<<https://ascelibrary.org/doi/full/10.1061/%28ASCE%29CP.1943-5487.0000041>>.

Acesso em: 17 set. 2019.

CHEN, B.; MATTHEWS, P. C.; TAVNER, P. J. Wind turbine pitch faults prognosis using a-priori knowledge-based ANFIS. **Expert Systems with Applications**, v. 40, n. 17, p. 6863-6876, dez. 2013. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0957417413003989>>. Acesso em: 17 set. 2019.

CHEN, S. et al. Music emotion recognition using deep Gaussian process. In: 7TH APSIPA ASC 2015, 7., 2015, Hong Kong. **Proceedings...** . Hong Kong: APSIPA, 2015. p. 495 - 498. Disponível em:

<<https://ieeexplore.ieee.org/abstract/document/7415321/>>. Acesso em: 05 ago. 2018.

CHEN, Y.; JHANG, Y.; LIANG, R. A fuzzy-logic based auto-scaling variable step-size MPPT method for PV systems. **Solar Energy**, v. 126, p. 53-63, mar. 2016.

<<https://www.sciencedirect.com/science/article/pii/S0038092X16000104>>. Acesso em 22 set. 2019.

CHIANG, W.; WANG, J.; HSU, Y. A music emotion recognition algorithm with hierarchical SVM based classifiers. In: 2014 INTERNATIONAL SYMPOSIUM ON COMPUTER, CONSUMER AND CONTROL, 2014, Taichung. **Proceedings...** . Taichung: IEEE, 2014. p. 1249 - 1252. Disponível em:

<<https://ieeexplore.ieee.org/abstract/document/6846115/>>. Acesso em: 05 ago. 2018.

CHOO, Y. H. et al. Music emotion recognition using chord progressions. In: 2016 IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS (SMC), 2016, Budapeste. **Proceedings...** . Budapeste: IEEE, 2016. p. 002588 - 002593. Disponível em: <<https://ieeexplore.ieee.org/document/7844628>>. Acesso em: 24 mar. 2019.

CLARK-POLNER, E.; JOHNSON, T. D.; BARRETT, L. F. Multivoxel pattern analysis does not provide evidence to support the existence of basic emotions. **Cerebral Cortex**, v. 27, n. 3, p.1944-1948, fev. 2016. Disponível em:

<<https://academic.oup.com/cercor/article/27/3/1944/3056293>>. Acesso em: 25 dez. 2018.

DALY, I. et al. Music-induced emotions can be predicted from a combination of brain activity and acoustic features. **Brain and Cognition**, v. 101, p. 1-11, dez. 2015. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0278262615300142?via%3Dihub>>. Acesso em: 01 jan. 2019.

DAMASIO, A. R. Emotions and feelings. In: MANSTEAD, A. S. R; FRIJDA, N.; FISCHER, A. **Feelings and emotions: The Amsterdam symposium**. Cambridge: Cambridge University Press, 2004. cap. 4, p.49-58.

DARWIN, C. **The expression of the emotions in man and animals**. 3. ed. Nova Iorque: Oxford University Press, 1998.

DECHTER, R.; PEARL, J. Generalized best-first search strategies and the optimality of A. **Journal of the ACM (JACM)**, v. 32, n. 3, p. 505-536, jul. 1985. Disponível em: <<https://dl.acm.org/citation.cfm?id=3830>>. Acesso em: 19 set. 2019.

DEFFERRARD, M. et al. Learning to recognize musical genre from audio: challenge overview. In: COMPANION OF THE THE WEB CONFERENCE 2018 ON THE WEB CONFERENCE 2018, 2018, Lyon. **Proceedings...** . Lyon: WWW '18, 2018. p-1921-1922. Disponível em: <<https://dl.acm.org/citation.cfm?id=3192310> >. Acesso em: 15 dez. 2018.

DE VRIES, D. et al. Music as a therapeutic intervention with autism: a systematic review of the literature. **Therapeutic Recreation Journal**, v. 49, n. 3, p.220-237, set. 2015. Disponível em: <<https://search.proquest.com/docview/1704374693?accountid=146694>>. Acesso em: 14 out. 2018.

DELBOUYS, R. et al. Music mood detection based on audio and lyrics with deep neural net. In: 19TH INTERNATIONAL SOCIETY FOR MUSIC INFORMATION RETRIEVAL CONFERENCE (ISMIR 2018), 19., 2018, Paris. **Proceedings...** . Paris: Ismir, 2018. p. 370 - 375. Disponível em: <<https://arxiv.org/abs/1809.07276>>. Acesso em: 24 mar. 2019.

DOGANTEKIN, E. et al. An intelligent diagnosis system for diabetes on linear discriminant analysis and adaptive network based fuzzy inference system: LDA-ANFIS. **Digital Signal Processing**, v. 20, n. 4, p. 1248-1255, jul. 2010. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1051200409001997>>. Acesso em: 11 out. 2019.

DOWNIE, J. S. Music information retrieval. **Annual Review of Information Science and Technology**, v. 37, n. 1, p.295-340, 31 jan. 2005. <<https://onlinelibrary.wiley.com/doi/10.1002/aris.1440370108>>. Acesso em: 08 dez. 2018.

DROSSOS, K.; FLOROS, A.; GRIGORIOS, N. Affective acoustic ecology: towards emotionally enhanced sound events. In: 7TH AUDIO MOSTLY CONFERENCE: A CONFERENCE ON INTERACTION WITH SOUND, 7., 2012, Corfu. **Proceedings...** . Corfu: ACM, 2012. p. 109 - 116. Disponível em: <<https://dl.acm.org/citation.cfm?id=2371474>>. Acesso em: 06 jan. 2019.

DUBOIS, D.; PRADE, H. What are fuzzy rules and how to use them. **Fuzzy sets and systems**, v. 84, n. 2, p. 169-185, dez. 1996. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0165011496000668>>. Acesso em: 04 mar. 2019.

EEROLA, T.; VUOSKOSKI, J. K. A comparison of the discrete and dimensional models of emotion in music. **Psychology of Music**, v.39, n.1, p. 18-49. 2011. Disponível em: <<https://journals.sagepub.com/doi/abs/10.1177/0305735610362821>>. Acesso em: 29 dez. 2018.

EGGINK, J.; BROWN, G.J. Instrument recognition in accompanied sonatas and concertos. In: 2004 IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING, 2004, Montreal. **Proceedings...**. Montreal: IEEE, 2004. p. 217 - 220. Disponível em: <<https://www.computer.org/csdl/proceedings/icassp/2004/8484/04/01326802-abs.html>>. Acesso em: 15 dez. 2018.

EKMAN, P. An argument for basic emotions. **Cognition and Emotion**, v. 6, n.3-4, p. 169-200, maio 1992. Disponível em: <<https://pdfs.semanticscholar.org/93d3/6be2da43bfe8303e718b061e7c6edf016256.pdf>>. Acesso em: 22 dez. 2018.

EKMAN, P.; CORDARO, D. What is meant by calling emotions basic? **Emotion Review**, v. 3, n. 4, p. 364-370, out. 2011. Disponível em: <<https://journals.sagepub.com/doi/abs/10.1177/1754073911410740>>. Acesso em: 22 dez. 2018.

EKMAN, P. What scientists who study emotion agree about. **Perspectives on Psychological Science**, v. 11, n.1, p.31-34, jan. 2016. Disponível em: <<https://journals.sagepub.com/doi/abs/10.1177/1745691615596992>>. Acesso em: 25 dez. 2018.

ELLIS, D. P. W. Beat tracking by dynamic programming. **Journal of New Music Research**, v. 36, n. 1, p.51-60, mar. 2007. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/09298210701653344>>. Acesso em: 25 jun. 2019.

FERNANDES, J. N. et al. Música e emoção: um estudo com alunos de graduação em música. **DEBATES-Cadernos do Programa de Pós-Graduação em Música**, n. 18, p.109-135, maio 2017. Disponível em: <<http://200.156.24.158/index.php/revistadebates/article/view/6549>>. Acesso em: 04 out. 2019.

FONTAINE, J.R.J. et al. The world of emotions is not two-dimensional. **Psychological Science**, v. 18, n. 12, p. 1050-1057, dez. 2007. Disponível em: <<https://www.ncbi.nlm.nih.gov/pubmed/18031411>>. Acesso em: 25 dez. 2018.

FUJIIHARA, H. et al. A modeling of singing voice robust to accompaniment sounds and its application to singer identification and vocal-timbre-similarity-based music information retrieval. **IEEE Transactions on Audio, Speech, and Language Processing**, v. 18, n. 3, p.638-648, mar. 2010. Disponível em: <<https://staff.aist.go.jp/m.goto/PAPER/IEEETASLP201003fujihara.pdf>>. Acesso em: 15 dez. 2018.

GAO, H.-L. et al. Mitigation of low frequency oscillations in power systems based on Mamdani fuzzy inference. **Transactions of the Institute of Measurement and Control**, p. 1-13, fev. 2019. Disponível em: <<https://journals.sagepub.com/doi/full/10.1177/0142331219826668>>. Acesso em: 05 mar. 2019.

GARDNER, M. W.; DORLING, S. R. Artificial neural networks (the multilayer perceptron) —a review of applications in the atmospheric sciences. **Atmospheric environment**, v. 32, n. 14-15, p. 2627-2636, 1998. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1352231097004470>>. Acesso em: 02 out. 2019.

GEORGANOS, S. et al. Less is more: Optimizing classification performance through feature selection in a very-high-resolution remote sensing object-based urban application. **GIScience & remote sensing**, v. 55, n. 2, p. 221-242, 2018. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/15481603.2017.1408892>>. Acesso em: 17 set. 2019.

GHORBANZADEH, O. et al. A new GIS-based data mining technique using an adaptive neuro-fuzzy inference system (ANFIS) and k-fold cross-validation approach for land subsidence susceptibility mapping. **Natural Hazards**, v. 94, n. 2, p.497-517, 23 ago. 2018. Disponível em: <<https://link.springer.com/article/10.1007/s11069-018-3449-y>>. Acesso em: 07 jul. 2019.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GOLDBERG, D. E.; HOLLAND, J. H. Genetic algorithms and machine learning. **Machine Learning**, v. 3, n. 2, p. 95-99, 1988. Disponível em: <<https://link.springer.com/article/10.1023%2FA%3A1022602019183?LI=true>>. Acesso em: 19 set. 2019.

GONZALEZ, C. I. et al. An improved sobel edge detection method based on generalized type-2 fuzzy logic. **Soft Computing**, v. 20, n. 2, p.773-784, 16 dez. 2014. Disponível em: <<https://link.springer.com/article/10.1007/s00500-014-1541-0>>. Acesso em: 13 jan. 2019.

GOSSELIN, N. Amygdala damage impairs emotion recognition from music. **Neuropsychologia**, v. 45, n. 2, p. 236-244, set. 2007. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0028393206003083?via%3Dihub>>. Acesso em: 01 jan. 2019.

GOYAL, M. K. et al. Modeling of daily pan evaporation in sub tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. **Expert Systems with Applications**, v. 41, n. 11, p. 5267-5276, set. 2014. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417414001237>>. Acesso em: 11 out. 2019.

GRAY, A.; MARKEL, J. A spectral-flatness measure for studying the autocorrelation method of linear prediction of speech analysis. **IEEE Transactions on Acoustics**,

Speech, and Signal Processing, v. 22, n. 3, p.207-217, jun. 1974. Disponível em: <<https://ieeexplore.ieee.org/document/1162572>>. Acesso em: 25 jun. 2019.

GÜLER, İ.; ÜBEYLI, E. D. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. **Journal of Neuroscience Methods**, v. 148, n. 2, p.113-121, out. 2005. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165027005001172>>. Acesso em: 06 abr. 2019.

GÜNERI, A. F.; ERTAY, T.; YÜCEL, A. An approach based on ANFIS input selection and modeling for supplier selection problem. **Expert Systems with Applications**, v. 38, n. 12, p.14907-14917, nov. 2011. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417411008402>>. Acesso em: 07 jul. 2019.

GURJAR, K.; MOON, Y. A comparative analysis of music similarity measures in music information retrieval systems. **Journal of Information Processing Systems**, v. 14, n. 1, p.32-55, fev. 2018. Disponível em: <<http://jips-k.org/q.jips?cp=pp&pn=527>>. Acesso em: 09 dez. 2018.

HALL, M. A. **Correlation-based Feature Selection for Machine Learning**. 1999. 198 f. Tese (Doutorado) - Curso de Computer Science, The University Of Waikato, Hamilton, 1999. Disponível em: <<https://www.cs.waikato.ac.nz/~mhall/thesis.pdf>>. Acesso em: 17 set. 2019.

HAN, W. et al. An efficient MFCC extraction method in speech recognition. In: 2006 IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS, 1., 2006, Cós. **Proceedings...** . Cós: Ieee, 2006. p. 145 - 148. Disponível em: <<https://ieeexplore.ieee.org/document/1692543>>. Acesso em: 25 jun. 2019.

HAN, Y.; KIM, J.; LEE, K. Deep convolutional neural networks for predominant instrument recognition in polyphonic music. **IEEE/ACM Transactions on Audio, Speech, and Language Processing**, v. 25, n. 1, p.208-221, jan. 2017. Disponível em: <<https://dl.acm.org/citation.cfm?id=3068697>>. Acesso em: 15 dez. 2018.

HAMANN, S. Mapping discrete and dimensional emotions onto the brain: Controversies and consensus. **Trends in Cognitive Sciences**, v.16, n.9, p. 458-466, set. 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364661312001726>>. Acesso em: 29 dez. 2018.

HARMON-JONES, E.; HARMON-JONES, C.; SUMMERELL, E. On the importance of both dimensional and discrete models of emotion. **Behavioral Sciences**, v.7, n.4, p. 1-16, set. 2017. Disponível em: <<https://www.mdpi.com/2076-328X/7/4/66>>. Acesso em: 29 dez. 2018.

HEVNER, K. Experimental studies of the elements of expression in music. **The American Journal of Psychology**, v. 48, n. 2, p.246-268, abr. 1936. Disponível em: <https://www.jstor.org/stable/1415746?seq=1#page_scan_tab_contents>. Acesso em: 13 jan. 2019.

HINOJOSA, J. A. et al. Affective norms of 875 Spanish words for five discrete emotional categories and two emotional dimensions. **Behavior Research Methods**, v.48, n.1, p.272-284, mar.2016. Disponível em:

<<https://link.springer.com/article/10.3758/s13428-015-0572-5>>. Acesso em 29 dez.2018.

HSIAO, S.; CHEN, S.; LEE, C. Methodology for stage lighting control based on music emotions. **Information Sciences**, v. 412-413, p.14-35, out. 2017. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0020025517307351>>. Acesso em: 04 ago. 2018.

HSU, J. et al. Affective content analysis of music emotion through EEG. **Multimedia Systems**, v. 24, n. 2, p.195-210, mar. 2017. Disponível em:

<<https://link.springer.com/article/10.1007/s00530-017-0542-0>>. Acesso em: 05 ago. 2018.

HU, Y.; CHEN, X.; YANG, D. Lyric-based song emotion detection with affective lexicon and fuzzy clustering method. In: 10TH INTERNATIONAL SOCIETY FOR MUSIC INFORMATION RETRIEVAL CONFERENCE (ISMIR 2009), 10., 2009, Kobe. **Proceedings...** . Kobe: Ismir, 2009. p. 123 - 128. Disponível em:

<<https://ismir2009.ismir.net/proceedings/PS1-12.pdf>>. Acesso em: 24 mar. 2019.

HUANG, S. et al. Empirical research on a fuzzy model of music emotion classification based on pleasure-arousal model. In: 37th Chinese Control Conference (CCC), 37., 2018, Wuhan. **Proceedings...** . Wuhan: IEEE, 2018. p.3239 - 3244. Disponível em:

<<https://ieeexplore.ieee.org/document/8483910>>. Acesso em: 20 abr. 2019.

HÜHN, J.; HÜLLERMEIER, E. FURIA: an algorithm for unordered fuzzy rule induction. **Data Mining and Knowledge Discovery**, v. 19, n. 3, p. 293-319, dez.

2009. Disponível em: <<https://link.springer.com/article/10.1007/s10618-009-0131-8>>. Acesso em: 03 mar. 2019.

HUO, J. et al. Review on neural correlates of emotion regulation and music:

Implications for emotion dysregulation. **Frontiers in Psychology**, v. 8, p. 1-8, abr. 2017. Disponível

em:<<https://www.frontiersin.org/articles/10.3389/fpsyg.2017.00501/full>>. Acesso em: 01 jan. 2019.

HUQ, A.; BELLO, J. P.; ROWE, R. Automated music emotion recognition: a systematic evaluation. **Journal of New Music Research**, v. 39, n. 3, p.227-244, set. 2010. Disponível em:

<<https://pdfs.semanticscholar.org/1a43/325def098ee57ff6f1c0b19a30811fe92304.pdf>>. Acesso em: 05 ago. 2018.

IZARD, C.E. **Human emotions**. Nova York: Springer Science & Business Media, 2013.

IZARD, C. E. Forms and functions of emotions: Matters of emotion–cognition interactions. **Emotion Review**, v. 3, n. 4, p. 371-378, out. 2011. Disponível em:

<<https://journals.sagepub.com/doi/10.1177/1754073911410737>>. Acesso em: 24 dez. 2018.

JANG, J. -SR. Fuzzy sets. In: JANG, J. -S. R.; SUN, C. -T.; MIZUTANI, E. **Neuro-fuzzy and Soft Computing: a computational approach to learning and machine intelligence**. Upper Saddle River: Prentice Hall, 1997a. Cap. 2. p. 13-46.

JANG, J. -SR. Fuzzy rules and fuzzy reasoning. In: JANG, J. -S. R.; SUN, C. -T.; MIZUTANI, E. **Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence**. Upper Saddle River: Prentice Hall, 1997b. Cap. 3. p. 47-72.

JANG, J. -SR. Fuzzy inference systems. In: JANG, J. -S. R.; SUN, C. -T.; MIZUTANI, E. **Neuro-fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence**. Upper Saddle River: Prentice Hall, 1997c. Cap. 4. p. 73-91.

JANG, J.-SR. ANFIS: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 23, n. 3, p. 665-685, 1993. Disponível em: <<https://ieeexplore.ieee.org/document/256541>>. Acesso em: 13 abr. 2019.

JANG, J.-SR. Input selection for ANFIS learning. In: IEEE 5TH INTERNATIONAL FUZZY SYSTEMS, 5., 1996, New Orleans. **Proceedings...** . New Orleans: IEEE, 1996. p. 1493 - 1499. Disponível em: <<https://ieeexplore.ieee.org/document/552396>>. Acesso em: 07 jul. 2019.

JÄSCHKE, R. et al. Tag recommendations in folksonomies. In: EUROPEAN CONFERENCE ON PRINCIPLES OF DATA MINING AND KNOWLEDGE DISCOVERY, 11., 2007, Varsóvia. **Proceedings...** . Varsóvia: Springer, 2007. p. 506 - 514. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-540-74976-9_52>. Acesso em: 11 jun. 2019.

JEON, B. et al. Music Emotion Recognition via End-to-End Multimodal Neural Networks. In: 11TH ACM CONFERENCE ON RECOMMENDER SYSTEMS, 11., 2017, Como. **Proceedings...** . Como: ACM, 2017. p. 1 - 2. Disponível em: <http://ceur-ws.org/Vol-1905/recsys2017_poster18.pdf>. Acesso em: 06 jan. 2018.

JIANG, D. et al. Music type classification by spectral contrast feature. In: IEEE INTERNATIONAL CONFERENCE ON MULTIMEDIA AND EXPO, 1., 2002, Lausana. **Proceedings...** . Lausana: IEEE, 2002. p. 113 - 116. Disponível em: <<https://ieeexplore.ieee.org/document/1035731>>. Acesso em: 25 jun. 2019.

JUN, S. et al. A fuzzy inference-based music emotion recognition system. In: 5TH INTERNATIONAL CONFERENCE ON VISUAL INFORMATION ENGINEERING (VIE 2008), 5., 2008, Xian. **Proceedings...** . Xian: IET, 2008. p. 673 - 677. Disponível em: <http://digital-library.theiet.org/content/conferences/10.1049/cp_20080398>. Acesso em: 14 out. 2018.

JUSLIN, P. N. From everyday emotions to aesthetic emotions: Towards a unified theory of musical emotions. **Physics of Life Reviews**, v. 10, n. 3, p.235-266, set. 2013. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1571064513000638?via%3Dihub>>. Acesso em: 31 dez. 2018.

KAMINSKAS, M.; RICCI, F. Contextual music information retrieval and recommendation: state of the art and challenges. **Computer Science Review**, v. 6, n. 2-3, p.89-119, maio 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1574013712000135>>. Acesso em: 08 dez. 2018.

KAWAKAMI, A.; FURUKAWA, K.; OKANOYA, K. Music evokes vicarious emotions in listeners. **Frontiers in Psychology**, v. 5, pag. 1-7, maio 2014. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpsyg.2014.00431/full>>. Acesso em: 01 jan. 2019.

KARABOGA, D.; KAYA, E. Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey. **Artificial Intelligence Review**, p. 1-31, jan. 2018. Disponível em: <<https://link.springer.com/article/10.1007/s10462-017-9610-2>>. Acesso em: 04 mar. 2019.

KARABULUT, E. M.; ÖZEL, S. A.; IBRIKCI, T. A comparative study on the effect of feature selection on classification accuracy. **Procedia Technology**, v. 1, p. 323-327, 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212017312000692>>. Acesso em: 17 set. 2019.

KARYOTIS, C. et al. A fuzzy computational model of emotion for cloud based sentiment analysis. **Information Sciences**, v. 433-434, p.448-463, abr. 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025517304164>>. Acesso em: 11 ago. 2018.

KESHAVARZI, A. et al. Application of ANFIS-based subtractive clustering algorithm in soil Cation Exchange Capacity estimation using soil and remotely sensed data. **Measurement**, v. 95, p.173-180, jan. 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224116305589>>. Acesso em: 08 jul. 2019.

KIM, Y. E. et al. Music emotion recognition: a state of the art review. In: 11TH INTERNATIONAL SOCIETY FOR MUSIC INFORMATION RETRIEVAL CONFERENCE (ISMIR 2010), 11., 2010, Utrecht. **Proceedings...** . Utrecht: ISMIR, 2010. p. 255 - 266. Disponível em: <<http://www.ismir2010.ismir.net/proceedings/ismir2010-45.pdf>>. Acesso em: 16 jan.2018.

KIM, Y. E.; WHITMAN, B. Singer identification in popular music recordings using voice coding features. In: 3RD INTERNATIONAL CONFERENCE ON MUSIC INFORMATION RETRIEVAL, 3., 2002, Paris. **Proceedings...** . Paris: ISMIR, 2002.

p. 1 - 6. Disponível em:

<<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.12.9971&rep=rep1&type=pdf>>. Acesso em: 15 dez. 2018.

KOELSCH, S. Brain correlates of music-evoked emotions. **Nature Reviews Neuroscience**, v. 15, p. 170-180, mar. 2014. Disponível em:

<<https://www.nature.com/articles/nrn3666>>. Acesso em 31 dez. 2018.

KOELSCH, S. Investigating the neural encoding of emotion with music. **Neuron**, v. 98, n. 6, p.1075-1079, jun. 2018. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0896627318303374?via%3Dihub>>. Acesso em: 31 dez. 2018.

KOVAC, P. et al. Application of fuzzy logic and regression analysis for modeling surface roughness in face milling. **Journal of Intelligent manufacturing**, v. 24, n. 4, p. 755-762, 2013. Disponível em: <<https://link.springer.com/article/10.1007/s10845-012-0623-z>>. Acesso em: 05 mar. 2019.

LAURIER, C. **Automatic classification of musical mood by content-based analysis**. 2011. 187 f. Tese (Doutorado) - Information and Communication Technologies, Information and Communication Technologies, Universitat Pompeu Fabra, Barcelona, 2011. Disponível em: <<https://goo.gl/82NkKg>>. Acesso em: 03 ago. 2018.

LAMERE, P. Social tagging and music information retrieval. **Journal of new music research**, v. 37, n. 2, p. 101-114, 2008. Disponível em:

<<https://www.tandfonline.com/doi/full/10.1080/09298210802479284>>. Acesso em: 26 maio 2019.

LEVENSON, R. W. Basic emotion questions. **Emotion Review**, v. 3, n. 4, p. 379-386, out. 2011. Disponível em:

<<https://journals.sagepub.com/doi/10.1177/1754073911410743>>. Acesso em: 24 dez. 2018.

LEWIS, D. D. Naive (Bayes) at forty: The independence assumption in information retrieval. In: 10TH EUROPEAN CONFERENCE ON MACHINE LEARNING, 10., 1998, Chemnitz. **Proceedings...** . Chemnitz: Springer, 1998. p. 4 - 15. Disponível em: <<https://link.springer.com/chapter/10.1007/BFb0026666>> . Acesso em: 02 out. 2019.

LI, T.; OGIHARA, M. Detecting emotion in music. In: 4TH INTERNATIONAL CONFERENCE ON MUSIC INFORMATION RETRIEVAL, 4., 2003, Baltimore. **Proceedings...** . Baltimore: Ismir, 2003. p. 1 - 2. Disponível em:

<<https://jscholarship.library.jhu.edu/handle/1774.2/41>>. Acesso em: 24 mar. 2019.

LIEM, C.C.S. **Multifaceted approaches to music information retrieval**. 2015. 179 f. Tese (Doutorado) - Curso de Electrical Engineering, Mathematics and Computer Science, Technische Universiteit Delft, Delft, 2015. Disponível em:

<<https://repository.tudelft.nl/islandora/object/uuid:e8a04372-4c55-4b5f-9bc3-aaab73fe649d/>>. Acesso em: 08 dez. 2018.

LIKKANEN, L. A.; ÅMAN, P. Shuffling services: current trends in interacting with digital music. **Interacting With Computers**, v. 28, n. 3, p.352-371, mar. 2015. Disponível em: <<https://academic.oup.com/iwc/article/28/3/352/1750711>>. Acesso em: 14 ago. 2018.

LINDQUIST, K. A. et al. The brain basis of emotion: A meta-analytic review. **Behavioral and Brain Sciences**, v. 35, n. 03, p.121-143, maio 2012. Disponível em: <<https://www.ncbi.nlm.nih.gov/pubmed/22617651>>. Acesso em: 29 dez. 2018.

LISBOA, C. A. **A intenção do intérprete e a percepção do ouvinte**: um estudo das emoções em música a partir da obra Piano Piece de Jmary Oliveira. 2008. 182 f. Tese (Doutorado) - Curso de Música, Universidade Federal da Bahia, Salvador, 2008. Disponível em: <<https://repositorio.ufba.br/ri/handle/ri/9116>>. Acesso em: 04 out. 2019.

LIU, T. et al. Audio-based deep music emotion recognition. **AIP Conference Proceedings**, p.040021-1-040021-4, maio 2018. Disponível em: <<https://aip.scitation.org/doi/abs/10.1063/1.5039095>>. Acesso em: 24 mar. 2019.

LIU, T.; SUN, S.; PAN, Y. Emotional recognition for chime bell music. In: 2004 IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN AND CYBERNETICS, 2004, Haia. **Proceedings...** . Haia: IEEE, 2004. p. 568 - 573. Disponível em: <<https://ieeexplore.ieee.org/document/1398360>>. Acesso em: 14 out. 2018.

LIU, X. Parameterized defuzzification with maximum entropy weighting function—another view of the weighting function expectation method. **Mathematical and Computer Modelling**, v. 45, n. 1-2, p. 177-188, jan. 2007. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0895717706001907>>. Acesso em: 29 set. 2019.

LÖVHEIM, H. A new three-dimensional model for emotions and monoamine neurotransmitters. **Medical hypotheses**, v. 78, n. 2, p. 341-348, fev. 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306987711005883>>. Acesso em: 04 out. 2019.

MALHEIRO, R. M. S. **Emotion-based analysis and classification of music lyrics**. 2016. 152 f. Tese (Doutorado) - Curso de Ciências e Tecnologias da Informação, Engenharia Informática, Universidade de Coimbra, Coimbra, 2016. Disponível em: <<http://repositorio.ismt.pt/bitstream/123456789/719/1/PhD%20Thesis%20-%20RicardoMalheiro.pdf>>. Acesso em: 05 ago. 2018.

MALHEIRO, R. et al. Emotionally-relevant features for classification and regression of music lyrics. **IEEE Transactions on Affective Computing**, v. 9, n. 2, p.240-254, 1 abr. 2018. Disponível em: <<https://ieeexplore.ieee.org/document/7536113>>. Acesso em: 24 mar. 2019.

MAMDANI, E.H.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. **International Journal of Man-machine Studies**, v. 7, n. 1, p.1-13, jan. 1975. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0020737375800022>. Acesso em: 21 out. 2018.

MANOGARAN, G.; VARATHARAJAN, R.; PRIYAN, M. K.. Hybrid Recommendation System for Heart Disease Diagnosis based on Multiple Kernel Learning with Adaptive Neuro-Fuzzy Inference System. **Multimedia Tools and Applications**, v. 77, n. 4, p.4379-4399, dez. 2017. Disponível em: <https://link.springer.com/article/10.1007/s11042-017-5515-y>. Acesso em: 06 abr. 2019.

MCFEE, B et al. librosa: Audio and music signal analysis in Python. In: 14TH PYTHON IN SCIENCE CONFERENCE, 14., 2015, Austin. **Proceedings...** . Austin: SciPy, 2015. p. 18 - 24. Disponível em: http://conference.scipy.org/proceedings/scipy2015/brian_mcfree.html. Acesso em: 10 jun. 2019.

MCKAY, C. **Automatic music classification with jMIR**. 2010. 600 f. Tese (Doutorado) - Curso de Music Technology, Music, McGill University, Montreal, 2010. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.165.2642&rep=rep1&type=pdf>. Acesso em: 22 jun. 2019.

MIREEI, S. A.; AMINI-POZVEH, S.; NAZERI, M. Selecting optimal wavelengths for detection of insect infested tomatoes based on SIMCA-aided CFS algorithm. **Postharvest Biology and Technology**, v. 123, p. 22-32, jan. 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0925521416302113> . Acesso em 20 set. 2019.

MITRA, S.; HAYASHI, Y. Neuro-fuzzy rule generation: survey in soft computing framework. **IEEE Transactions on Neural Networks**, v. 11, n. 3, p. 748-768, 2000. Disponível em: <https://ieeexplore.ieee.org/document/846746>. Acesso em: 07 abr. 2019.

MOHAMMADPOUR, M.et al. Music emotion recognition based on Wigner-Ville distribution feature extraction. In: 4TH INTERNATIONAL CONFERENCE ON KNOWLEDGE-BASED ENGINEERING AND INNOVATION (KBEI-2017), 4., 2017, Tehran. **Proceedings...** . Tehran: Ieee, 2017. p. 12 - 16. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8324963/>. Acesso em: 04 ago. 2018.

MÖSSLER, K. et al. The therapeutic relationship as predictor of change in music therapy with young children with Autism Spectrum Disorder. **Journal of Autism and Developmental Disorders**, p.1-15, set. 2017. Disponível em: <https://link.springer.com/article/10.1007/s10803-017-3306-y>. Acesso em: 14 out. 2018.

MOTAMED, S.; SETAYESHI, S.; RABIEE, A. Speech emotion recognition based on a modified brain emotional learning model. **Biologically Inspired Cognitive Architectures**, v. 19, p. 32-38, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212683X16301219>>. Acesso em: 07 abr. 2019.

MURTHY, Y. V. S.; KOOLAGUDI, S. G. Content-based music information retrieval (CB-MIR) and its applications toward the music industry. **Acm Computing Surveys**, v. 51, n. 3, p.1-46, 12 jun. 2018. Disponível em: <<https://dl.acm.org/citation.cfm?id=3177849>>. Acesso em: 09 dez. 2018.

NALINI, N. J.; PALANIVEL, S. Music emotion recognition: The combined evidence of MFCC and residual phase. **Egyptian Informatics Journal**, v. 17, n. 1, p. 1-10, mar. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1110866515000419>>. Acesso em 31 mar. 2019.

NANI, L. et al. Combining visual and acoustic features for music genre classification. **Expert Systems with Applications**, v. 45, p. 108-117, mar. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417415006326>>. Acesso em: 22 dez. 2018.

NAUCK, D.; KRUSE, R. A neuro-fuzzy method to learn fuzzy classification rules from data. **Fuzzy Sets and Systems**, v. 89, n. 3, p. 277-288, 1997. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165011497000092>>. Acesso em 31 mar. 2019.

NGUYEN, H. T.; WALKER, C. L.; WALKER, E. A. **A first course in fuzzy logic**. Nova Iorque: CRC Press, 2018.

NIKOLAOU, N. **Music emotion classification**. 2011. 136 f. Dissertação (Mestrado) - Curso de Electronic & Computer Engineer, Electronic & Computer Engineering, Technical University of Crete, Creta, 2011. Disponível em: <<https://goo.gl/URWekb>>. Acesso em: 03 ago. 2018.

ORIO, N. Music retrieval: a tutorial and review. **Foundations and Trends® in Information Retrieval**, v. 1, n. 1, p.1-96, 2006. Disponível em: <<https://ieeexplore.ieee.org/document/8186869?arnumber=8186869>>. Acesso em: 08 dez. 2018.

ORTONY, A.; CLORE, G. L.; COLLINS, A. **The cognitive structure of emotions**. Cambridge: Cambridge University Press, 1990.

PANDA, R.; PAIVA, R. P. Automatic creation of mood playlists in the thayer plane: a methodology and a comparative study. In: 8TH SOUND AND MUSIC COMPUTING CONFERENCE, 8., 2011, Padova. **Proceedings...** . Padova: Smc, 2011. p. 1 - 8. Disponível em: <http://smcnetwork.org/system/files/smc2011_submission_156.pdf>. Acesso em: 04 ago. 2018.

PANDA, R.; ROCHA, B.; PAIVA, R. P. Music emotion recognition with standard and melodic audio features. **Applied Artificial Intelligence**, v. 29, n. 4, p.313-334, abr. 2015. Disponível em:
<<https://www.tandfonline.com/doi/abs/10.1080/08839514.2015.1016389>>. Acesso em: 05 ago. 2018.

PEKALA, B. **Uncertainty data in interval-valued fuzzy set theory**: properties, algorithms and applications. Cham: Springer, 2018.

PLUTCHIK, R. Measurement implications of a psychoevolutionary theory of emotions. In: BLANKSTEIN, K. R.; PLINNER, P.; POLIVY, J. **Assessment and modification of emotional behavior**. Boston: Springer, 1980. cap.3, p. 47-69.

POLLACCI, L. et al. The italian music superdiversity. **Multimedia Tools and Applications**, v. 78, n. 3, p.3297-3319, 17 set. 2018. Disponível em:
<<https://link.springer.com/article/10.1007/s11042-018-6511-6>>. Acesso em: 26 maio 2019.

POSNER, J.; RUSSELL, J. A.; PETERSON, B. S. The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology. **Development and Psychopathology**, v. 17, n. 3, p. 715-734, set. 2005. Disponível em:
<<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2367156/#R135>>. Acesso em: 25 dez. 2018.

QUINLAN, J R. **C4.5: Programs for Machine Learning**. San Mateo: Elsevier, 2014.

ROSS, T. J. **Fuzzy logic with engineering applications**. Chichester: John Wiley & Sons, 2005.

RUSSELL, J. A. A circumplex model of affect. **Journal of Personality and Social Psychology**, v.39, n.6, p. 1161-1178, 1980.

RUSSELL, J. A. Core affect and the psychological construction of emotion. **Psychological Review**, v. 110, n. 1, p. 145-172, 2003. Disponível em:
<http://ivizlab.sfu.ca/arya/Papers/Others/Emotions/Core_Affect.pdf>. Acesso em: 22 dez. 2018.

SAARIMÄKI, H. et al. Discrete neural signatures of basic emotions. **Cerebral Cortex**, v. 26, n. 6, p-2563-2573, abr. 2015. Disponível em:
<<https://academic.oup.com/cercor/article/26/6/2563/1754140>>. Acesso em: 25 dez. 2018.

SAIZ-CLAR, E.; REALES, J. M. Predicting emotional response to music through a compound neural network. **Psychology of Music**, v. 46, n. 2, p.222-237, 18 maio 2017. Disponível em:
<<https://journals.sagepub.com/doi/abs/10.1177/0305735617705452>>. Acesso em: 13 jan. 2019.

SAKKA, L. S.; JUSLIN, P. N. Emotion regulation with music in depressed and non-depressed individuals: Goals, strategies, and mechanisms. **Music & Science**, v. 1, p. 1-12. Disponível em: <<https://journals.sagepub.com/doi/full/10.1177/2059204318755023>>. Acesso em: 01 jan. 2019.

SALAHSHOOR, K.; KORDESTANI, M.; KHOSHRO, M. S. Fault detection and diagnosis of an industrial steam turbine using fusion of SVM (support vector machine) and ANFIS (adaptive neuro-fuzzy inference system) classifiers. **Energy**, v. 35, n. 12, p.5472-5482, dez. 2010. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544210003154>>. Acesso em: 07 jul. 2019.

SARI, W. E.; WAHYUNGGORO, O.; FAUZIATI, S. A comparative study on fuzzy Mamdani-Sugeno-Tsukamoto for the childhood tuberculosis diagnosis. **AIP Conference Proceedings**, v. 1755, n. 1, p. 070003-1-070003-6, jul. 2016. Disponível em: <<https://aip.scitation.org/doi/pdf/10.1063/1.4958498>>. Acesso em: 05 mar. 2019.

SCHEDL, M. Investigating country-specific music preferences and music recommendation algorithms with the LFM-1b dataset. **International Journal of Multimedia Information Retrieval**, v. 6, n. 1, p.71-84, 6 fev. 2017. Disponível em: <<https://link-springer-com.ez22.periodicos.capes.gov.br/content/pdf/10.1007%2Fs13735-017-0118-y.pdf>>. Acesso em: 08 dez. 2018.

SCHEDL, M.; GÓMEZ, E.; URBANO, J. Music information retrieval: recent developments and applications. **Foundations and Trends® in Information Retrieval**, v. 8, n. 2-3, p.127-261, 2014. Disponível em: <<https://www.nowpublishers.com/article/Details/INR-042>>. Acesso em: 08 dez. 2018.

SCHMIDT, E. M.; SCOTT, J.; KIM, Y. E. Feature learning in dynamic environments: modeling the acoustic structure of musical emotion. In: 13TH INTERNATIONAL SOCIETY FOR MUSIC INFORMATION RETRIEVAL CONFERENCE, 13., 2012, Porto. **Proceedings...** . Porto: ISMIR, 2012. p. 325 - 330. Disponível em: <<http://music.ece.drexel.edu/files/Navigation/Publications/Schmidt2012b.pdf>>. Acesso em: 06 jan. 2019.

SCHMIDT, E. M.; TURNBULL, D.; KIM, Y. E. Feature selection for content-based, time-varying musical emotion regression. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON MULTIMEDIA INFORMATION RETRIEVAL, 11., 2010, Filadélfia. **Proceedings...** . Filadélfia: ACM, 2010. p. 267 - 274. Disponível em: <<https://dl.acm.org/citation.cfm?id=1743431>>. Acesso em: 24 mar. 2019.

SCHUBERT, E. Update of the Hevner adjective checklist. **Perceptual and Motor Skills**, v. 96, n. 3, p.1117-1122, jun. 2003. Disponível em: <<https://journals.sagepub.com/doi/abs/10.2466/pms.2003.96.3c.1117>>. Acesso em: 13 jan. 2019.

SHARMA, L. K.; VISHAL, Vikram; SINGH, T. N. Predicting CO₂ permeability of bituminous coal using statistical and adaptive neuro-fuzzy analysis. **Journal of Natural Gas Science and Engineering**, v. 42, p. 216-225, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1875510017300902>>. Acesso em: 07 abr. 2019.

SHEN, C. et al. Basic emotions expressed in music: factor analyses on intensity ratings by non-musical professional Chinese university students. **Psychology Research and Behavior Management**, v. 11, p.617-629, dez. 2018. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6294065/>>. Acesso em: 13 jan. 2019.

SHWEDER, R. A. Deconstructing the emotions for the sake of comparative research. In: MANSTEAD, A. S. R.; FRIJDA, N.; FISCHER, A. (Ed.). **Feelings and emotions: The Amsterdam symposium**. Cambridge: Cambridge University Press, 2004. p. 81-98.

SIDDIQUE, N.; ADELI, H. **Computational Intelligence: Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing**. Chichester: John Wiley & Sons, 2013.

SIEDENBURG, K.; FUJINAGA, I.; McADAMS, S. A comparison of approaches to timbre descriptors in music information retrieval and music psychology. **Journal of New Music Research**, v. 45, n. 1, p.27-41, 2 jan. 2016. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/09298215.2015.1132737>>. Acesso em: 09 dez. 2018.

SILLA JR, C. N.; KOERICH, A. L.; KAESTNER, C. A. A. A Machine Learning Approach to Automatic Music Genre Classification. **Journal of the Brazilian Computer Society**, v. 14, n. 3, p.7-18, set. 2008. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0104-65002008000300002>. Acesso em: 07 jul. 2019.

SOLEYMANI, M et al. 1000 songs for emotional analysis of music. In: 2ND ACM INTERNATIONAL WORKSHOP ON CROWDSOURCING FOR MULTIMEDIA, 2., 2013, Barcelona. **Proceedings...** . Barcelona: ACM, 2013. p. 1 - 6. Disponível em: <<https://dl.acm.org/citation.cfm?id=2506365>>. Acesso em: 08 jun. 2019.

SON, L. H.; VAN VIET, P.; VAN HAI, P. Picture inference system: a new fuzzy inference system on picture fuzzy set. **Applied Intelligence**, v. 46, n. 3, p. 652-669, abr. 2017. Disponível em: <<https://link.springer.com/article/10.1007/s10489-016-0856-1>>. Acesso em: 05 mar. 2019.

SONG, Y.; DIXON, S.; PEARCE, M. Evaluation of musical features for emotion classification. In: 13TH INTERNATIONAL SOCIETY FOR MUSIC INFORMATION RETRIEVAL CONFERENCE (ISMIR 2012), 13., 2012, Porto. **Proceedings...** . Porto: Ismir, 2012. p. 523 - 528. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.294.4218&rep=rep1&type=pdf>>. Acesso em: 05 ago. 2018.

SU, L.; YANG, Y. Sparse modeling for artist identification: exploiting phase information and vocal separation. In: 14TH INTERNATIONAL SOCIETY FOR MUSIC

INFORMATION RETRIEVAL CONFERENCE, 14., 2013, Curitiba. **Proceedings...** . Curitiba: ISMIR, 2013. p. 1 - 6. Disponível em: <http://www.ppgia.pucpr.br/ismir2013/wp-content/uploads/2013/09/54_Paper.pdf>. Acesso em: 15 dez. 2018.

SUBASI, A. Classification of EMG signals using combined features and soft computing techniques. **Applied Soft Computing**, v. 12, n. 8, p.2188-2198, ago. 2012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494612001330>>. Acesso em: 07 jul. 2019.

SUGANTHI, L.; INIYAN, S.; SAMUEL, A. A. Applications of fuzzy logic in renewable energy systems – a review. **Renewable and Sustainable Energy Reviews**, v. 48, p.585-607, ago. 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S136403211500307X>>. Acesso em: 12 jan. 2019.

SWAMINATHAN, S.; SCHELLENBERG, E. G. Current emotion research in music psychology. **Emotion Review**, v. 7, n. 2, p. 189-197, abr. 2015. Disponível em: <<https://journals.sagepub.com/doi/abs/10.1177/1754073914558282>>. Acesso em: 01 jan. 2019.

SYAHPUTRA, R. Application of neuro-fuzzy method for prediction of vehicle fuel consumption. **Journal of Theoretical & Applied Information Technology**, v. 86, n. 1, p. 138-150, 2016. Disponível em: <<http://www.jatit.org/volumes/Vol86No1/15Vol86No1.pdf>>. Acesso em 31 mar. 2019.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **IEEE Transactions on Systems, Man, And Cybernetics**, v. SMC -15, n. 1, p.116-132, jan. 1985. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/6313399>>. Acesso em: 21 out. 2018.

TAVRIS, C. Introduction: A point of view. In: TAVRIS, C. **Anger: The misunderstood emotion**. Nova Iorque: Simon And Schuster, 1989. p. 17-26.

THAMMASAN, N.; FUKUI, K.; NUMAO, M. Multimodal fusion of eeg and musical features in music-emotion recognition. In: THIRTY-FIRST AAAI CONFERENCE ON ARTIFICIAL INTELLIGENCE, 31., 2017, São Francisco. **Proceedings...** . São Francisco: AAAI, 2017. p. 4991 - 4992. Disponível em: <<https://www.aaai.org/ocs/index.php/AAAI/AAAI17/paper/viewPaper/14831>>. Acesso em: 24 mar. 2019.

TERMEH, S. V. Razavi et al. Flood susceptibility mapping using novel ensembles of adaptive neuro fuzzy inference system and metaheuristic algorithms. **Science of the Total Environment**, v. 615, p. 438-451, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0048969717326141>>. Acesso em: 07 abr. 2019.

TOOSI, A. N.; KAHANI, M. A new approach to intrusion detection based on an evolutionary soft computing model using neuro-fuzzy classifiers. **Computer**

Communications, v. 30, n. 10, p.2201-2212, jul. 2007. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0140366407001855>>. Acesso em: 08 jul. 2019.

TOOSI, A. N.; KAHANI, M.; MONSEFI, R. Network intrusion detection based on neuro-fuzzy classification. In: 2006 IEEE International Conference on Computing & Informatics (ICOCI 2006), 1., 2006, Kuala Lumpur. **Proceedings...** . Kuala Lumpur: IEEE, 2006. p. 1 - 5. Disponível em: <<https://ieeexplore.ieee.org/document/5276608>>. Acesso em: 08 jul. 2019.

TRACY, J. L.; RANDLES, D. Four models of basic emotions: A review of Ekman and Cordaro, Izard, Levenson, and Panksepp and Watt. **Emotion Review**, v. 3, n. 4, p. 397-405, out. 2011. Disponível em: <<https://journals.sagepub.com/doi/pdf/10.1177/1754073911410747>>. Acesso em: 24 dez. 2018.

TSUKAMOTO, Y. An approach to fuzzy reasoning method. In: GUPTA, M. M., RAGADE, R. K., YAGER, R. R. **Advances in fuzzy set theory and applications**. Amsterdã: Elsevier, 1979. p. 137–149.

TZANETAKIS, G.; COOK, P. Musical genre classification of audio signals. **IEEE Transactions on Speech and Audio Processing**, v. 10, n. 5, p. 293-302, set. 2002. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/1021072>>. Acesso em: 22 dez. 2018.

VEIRMAN, E.; FONTAINE, J. R. J. Revisiting the dimensional structure of the emotion domain. **Cognition and Emotion**, v. 29, n. 6, p. 1026-1041, out. 2014. Disponível: <<https://www.tandfonline.com/doi/abs/10.1080/02699931.2014.963518>>. Acesso em: 30 dez. 2018.

WANG, D. et al. Image feature-based affective retrieval employing improved parameter and structure identification of adaptive neuro-fuzzy inference system. **Neural Computing and Applications**, v. 29, n. 4, p. 1087-1102, 2018. Disponível em: <<https://link.springer.com/article/10.1007/s00521-016-2512-4>>. Acesso em: 07 abr. 2019.

WANG, J.; WANG, H.; LANCKRIET, G. A histogram density modeling approach to music emotion recognition. In: 2015 IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNAL PROCESSING (ICASSP), 40., 2015, Brisbane. **Proceedings...** . Brisbane: IEEE, 2015. p. 698 - 702. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/7178059/>>. Acesso em: 05 ago. 2018.

WEISGERBER, A. et al. Facial, vocal and musical emotion recognition is altered in paranoid schizophrenic patients. **Psychiatry Research**, v. 229, n. 1-2, p.188-193, set. 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165178115004990>>. Acesso em: 14 out. 2018.

WUNDT, W. M. **Principles of physiological psychology**. 5. ed. Nova Iorque: The Macmillan CO, 1904.

YÄICI, W.; ENTCHEV, E. Adaptive Neuro-Fuzzy Inference System modelling for performance prediction of solar thermal energy system. **Renewable Energy**, v. 86, p. 302-315, 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960148115302287>>. Acesso em: 13 abr. 2019.

YAN, H.; ZOU, Z.; WANG, H. Adaptive neuro fuzzy inference system for classification of water quality status. **Journal of Environmental Sciences**, v. 22, n. 12, p.1891-1896, dez. 2010. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1001074209603351>>. Acesso em: 07 jul. 2019.

YANG, X.; DONG, Y.; LI, J. Review of data features-based music emotion recognition methods. **Multimedia Systems**, v. 24, n. 4, p.365-389, ago. 2017. Disponível em: <<https://link.springer.com/article/10.1007/s00530-017-0559-4>>. Acesso em: 11 ago. 2018.

YANG, Y.; CHEN, H. H. Music emotion ranking. In: 2009 IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNAL PROCESSING, 34., 2009, Taipei. **Proceedings...**. Taipei: IEEE, 2009. p. 1657 - 1660. Disponível em: <<https://ieeexplore.ieee.org/document/4959919>>. Acesso em: 06 jan. 2019.

YANG, Y.; CHEN, H. H. **Music emotion recognition**. Nova Iorque: CRC Press, 2011.

YANG, Y.; CHEN, H. H. Machine recognition of music emotion: A review. **ACM Transactions on Intelligent Systems and Technology**, v. 3, n. 3, p.1-30, maio 2012. Disponível em: <<https://dl.acm.org/citation.cfm?id=2168754>>. Acesso em: 04 ago. 2018.

YANG, Y.; LIU, C.; CHEN, H. H. Music emotion classification: a fuzzy approach. In: THE 14TH ACM INTERNATIONAL CONFERENCE ON MULTIMEDIA, 14., 2006, Santa Barbara. **Proceedings...**. Santa Barbara: Acm, 2006. p. 81 - 84. Disponível em: <<https://dl.acm.org/citation.cfm?id=1180665>>. Acesso em: 11 ago. 2018.

YANG, Y. et al. A regression approach to music emotion recognition. **IEEE Transactions on Audio, Speech, and Language Processing**, v. 16, n. 2, p.448-457, fev. 2008. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/4432654/>>. Acesso em: 05 ago. 2018.

YU, H. et al. Tag recommendation method in folksonomy based on user tagging status. **Journal of Intelligent Information Systems**, p. 1-22, 2018. Disponível em: <<https://link.springer.com/content/pdf/10.1007/s10844-017-0468-1.pdf>>. Acesso em: 10 jun. 2019

ZADEH, L.A. Fuzzy sets. **Information and Control**, v. 8, n. 3, p.338-353, jun. 1965. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S001999586590241X>>. Acesso em: 21 out. 2018.

ZADEH, L. A. Knowledge representation in fuzzy logic. In: YAGER, R. R.; ZADEH, L. A. (Ed.). **An introduction to fuzzy logic applications in intelligent systems**. Nova Iorque: Springer Science & Business Media, 1992. Cap. 1. p. 1-26.

ZADEH, L. A. Is there a need for fuzzy logic? **Information Sciences**, v. 178, n. 13, p.2751-2779, jul. 2008. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0020025508000716>>. Acesso em: 12 jan. 2019.

ZADEH, L. A. Fuzzy logic—a personal perspective. **Fuzzy Sets and Systems**, v. 281, p.4-20, dez. 2015. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0165011415002377>>. Acesso em: 12 jan. 2018.

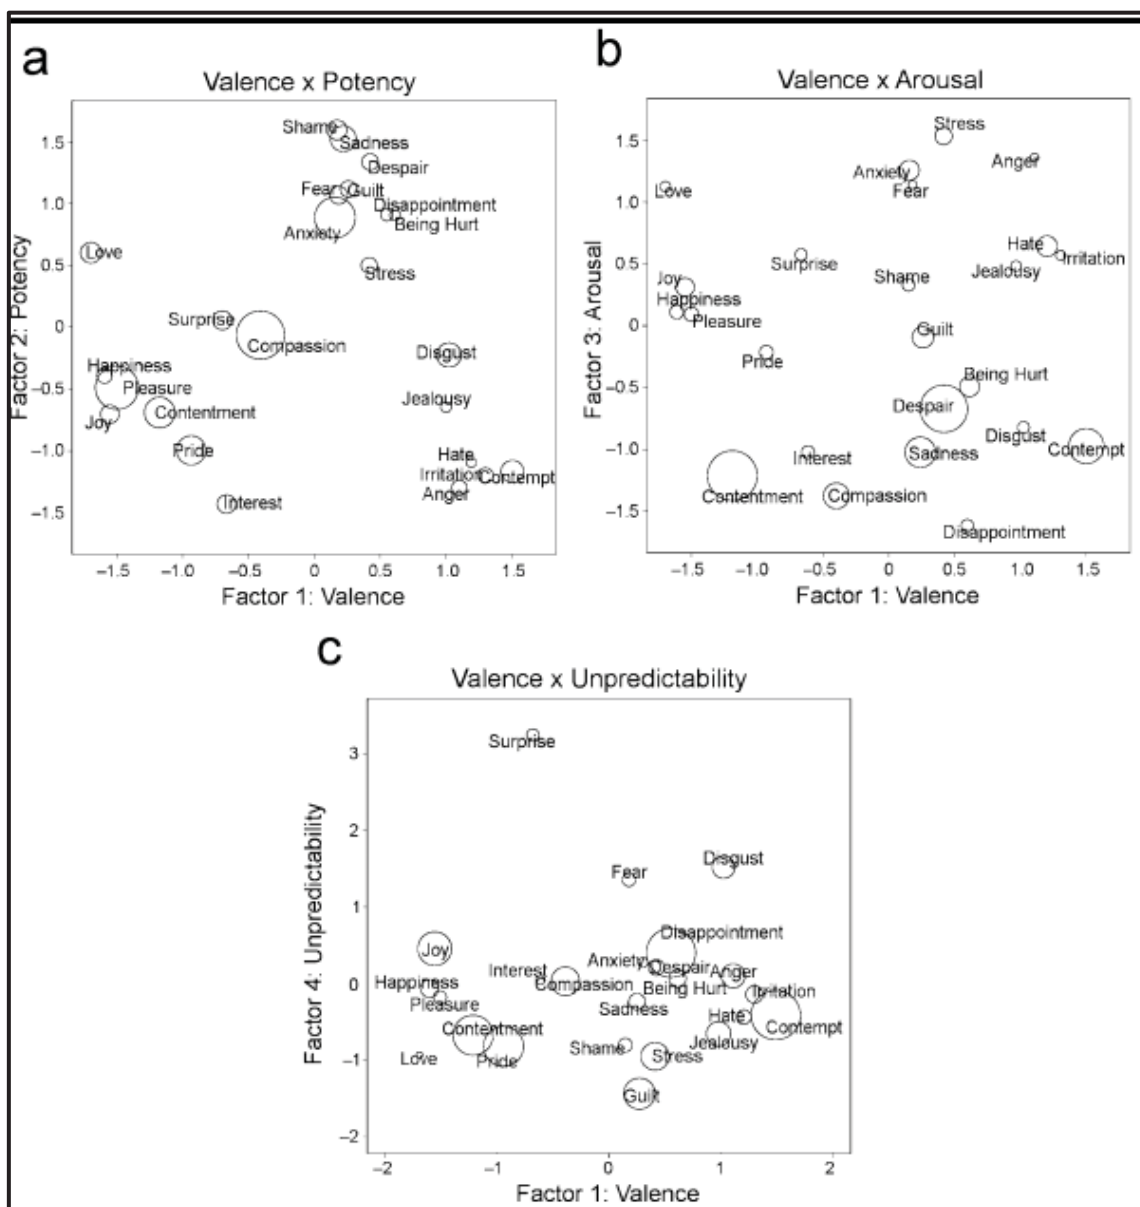
ZHANG, J. et al. An ANFIS-based fault classification approach in power distribution system. **International Journal of Electrical Power & Energy Systems**, v. 49, p.243-252, jul. 2013. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0142061513000136>>. Acesso em: 07 jul. 2019.

ZHANG, J. et al. Bridge the semantic gap between pop music acoustic feature and emotion: build an interpretable model. **Neurocomputing**, v. 208, p.333-341, out. 2016. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0925231216304696>>. Acesso em: 05 ago. 2018.

ZHANG, L.; TJONDRONEGORO, D.; CHANDRAN, Vinod. Representation of facial expression categories in continuous arousal–valence space: Feature and correlation. **Image and Vision Computing**, v. 32, n. 12, p. 1067-1079, dez. 2014. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0262885614001449>>. Acesso em: 20 abr. 2019.

ZHU, B; ZHAO, F; TANG, Y. C. A new fuzzy classifier for music emotion based on conditional probability. In: INTERNATIONAL CONFERENCE ON INFORMATION ELECTRONIC AND COMPUTER SCIENCE, 1., 2010, Zibo. **Proceedings...**. Zibo: Scientific Research Publishing Inc., 2010. p. 1371 - 1375.

ANEXO A - MODELO PROPOSTO POR FONTAINE et al. (2007)



Fonte: Fontaine et al. (2007, p.1055).

APÊNDICE A – ENDEREÇO DAS *PLAYLISTS* ELABORADAS

Playlist - Felicidade (Happiness)

<https://www.youtube.com/watch?v=GXyp4bYOZEc&list=PLct-3iye9zrea4scW9fvymOaPg1YKEbmB>

Playlist - Medo (Fear)

<https://www.youtube.com/watch?v=DcQzATCJpBA&list=PLct-3iye9zrcPSQ-9TKcKQqSjVJZxRr86>

Playlist - Raiva (Anger)

https://www.youtube.com/watch?v=ar9BaNN5J4E&list=PLct-3iye9zrcu_a1FhEfR3LMPmTtGNyf_

Playlist - Surpresa (Surprise)

<https://www.youtube.com/watch?v=T16IF-BHwAw&list=PLct-3iye9zrdfZBmQzloWOxUAzQuXPt1K>

Playlist - Tristeza (Sadness)

https://www.youtube.com/watch?v=y8AWFf7EAc4&list=PLct-3iye9zrc5KwTwRkQSA7gMmFF2FLZ_

APÊNDICE B – *SCRIPT PARA DOWNLOAD DOS ARQUIVOS .MP3*

Importar biblioteca

```
import youtube_dl
```

Passar endereço da playlist

```
playlist = 'https://www.youtube.com/playlist?list=PLct-3iye9zrc5KwTwRkQSA7gMmFF2FLZ_'
```

Baixar somente o áudio

```
yd_opts = {  
    'playliststart': 1,  
    'format': 'bestaudio/best',  
    'postprocessors': [{  
        'key': 'FFmpegExtractAudio',  
        'preferredcodec': 'mp3',  
        'preferredquality': '128',  
    }],  
    'ignoreerrors': True,  
}
```

```
with youtube_dl.YoutubeDL(yd_opts) as ydl:  
    ydl.download([playlist])
```

APÊNDICE C – SCRIPT PARA A EXTRAÇÃO DE DESCRITORES

Adaptado de: <https://github.com/danz1ka19/Music-Emotion-Recognition>

Importar bibliotecas

```
import librosa, numpy as np, pandas as pd
from os import listdir
from os.path import isfile, join
```

Criar função de extração

```
def extrair_descritores(path):
    id = 1 # ID da música
    feature_set = pd.DataFrame() # Matriz de descritores
```

Definir descritores

```
songname_vector = pd.Series()
harmonic_mean = pd.Series()
harmonic_std = pd.Series()
tempo_vector = pd.Series()
total_beats = pd.Series()
pitch_mean = pd.Series()
pitch_std = pd.Series()
mfcc_mean_1 = pd.Series()
mfcc_std_1 = pd.Series()
mfcc_mean_2 = pd.Series()
mfcc_std_2 = pd.Series()
mfcc_mean_3 = pd.Series()
mfcc_std_3 = pd.Series()
mfcc_mean_4 = pd.Series()
mfcc_std_4 = pd.Series()
mfcc_mean_5 = pd.Series()
mfcc_std_5 = pd.Series()
rmse_mean = pd.Series()
rmse_std = pd.Series()
centroid_mean = pd.Series()
centroid_std = pd.Series()
contrast_mean = pd.Series()
contrast_std = pd.Series()
flatness_mean = pd.Series()
flatness_std = pd.Series()
rolloff_mean = pd.Series()
rolloff_std = pd.Series()
zcr_mean = pd.Series()
zcr_std = pd.Series()
```

Iterando pelos arquivos

```
file_data = [f for f in listdir(path) if isfile(join(path, f))]
for line in file_data:
    if (line[-1:] == '\n'):
        line = line[:-1]
```

Lendo as músicas

```
songname = path + line
y, sr = librosa.load(songname)
S = np.abs(librosa.stft(y))
```

Extraíndo os descritores

```
tempo, beats = librosa.beat.beat_track(y=y, sr=sr)
pitch = librosa.effects.pitch_shift(y=y, sr=sr, n_steps=4)
harmonic = librosa.effects.harmonic(y)
mfcc = librosa.feature.mfcc(y=y, sr=sr, n_mfcc=5)
rmse = librosa.feature.rmse(y=y)
centroid = librosa.feature.spectral_centroid(y=y, sr=sr)
flatness = librosa.feature.spectral_flatness(y=y)
contrast = librosa.feature.spectral_contrast(S=S, sr=sr)
rolloff = librosa.feature.spectral_rolloff(y=y, sr=sr)
zcr = librosa.feature.zero_crossing_rate(y)
```

Transformar os descritores

```
songname_vector.set_value(id, line) # nome
tempo_vector.set_value(id, tempo) # tempo
total_beats.set_value(id, sum(beats)) # beats
pitch_mean.set_value(id, np.mean(pitch)) # pitch
pitch_std.set_value(id, np.std(pitch))
harmonic_mean.set_value(id, np.mean(harmonic)) # harmonic
harmonic_std.set_value(id, np.std(harmonic))
mfcc_mean_1.set_value(id, np.mean(mfcc[0:,0])) # mfcc
mfcc_std_1.set_value(id, np.std(mfcc[0:,0]))
mfcc_mean_2.set_value(id, np.mean(mfcc[0:,1]))
mfcc_std_2.set_value(id, np.std(mfcc[0:,1]))
mfcc_mean_3.set_value(id, np.mean(mfcc[0:,2]))
mfcc_std_3.set_value(id, np.std(mfcc[0:,2]))
mfcc_mean_4.set_value(id, np.mean(mfcc[0:,3]))
mfcc_std_4.set_value(id, np.std(mfcc[0:,3]))
mfcc_mean_5.set_value(id, np.mean(mfcc[0:,4]))
mfcc_std_5.set_value(id, np.std(mfcc[0:,4]))
rmse_mean.set_value(id, np.mean(rmse)) # rmse
rmse_std.set_value(id, np.std(rmse))
centroid_mean.set_value(id, np.mean(centroid)) # centroid
centroid_std.set_value(id, np.std(centroid))
contrast_mean.set_value(id, np.mean(contrast)) # contrast
contrast_std.set_value(id, np.std(contrast))
flatness_mean.set_value(id, np.mean(flatness)) # flatness
flatness_std.set_value(id, np.std(flatness))
rolloff_mean.set_value(id, np.mean(rolloff)) # rolloff
rolloff_std.set_value(id, np.std(rolloff))
zcr_mean.set_value(id, np.mean(zcr)) # zero crossing rate
zcr_std.set_value(id, np.std(zcr))
print(songname)
id = id + 1
```

Concatenar valores

```
feature_set['song_name'] = songname_vector # nome
feature_set['tempo'] = tempo_vector # tempo
feature_set['total_beats'] = total_beats # beats
feature_set['pitch_mean'] = pitch_mean # pitch
feature_set['pitch_std'] = pitch_std
feature_set['harmonic_mean'] = harmonic_mean # harmonic
feature_set['harmonic_std'] = harmonic_std
feature_set['mfcc_mean_1'] = mfcc_mean_1 # mfcc
feature_set['mfcc_std_1'] = mfcc_std_1
feature_set['mfcc_mean_2'] = mfcc_mean_2
feature_set['mfcc_std_2'] = mfcc_std_2
feature_set['mfcc_mean_3'] = mfcc_mean_3
feature_set['mfcc_std_3'] = mfcc_std_3
feature_set['mfcc_mean_4'] = mfcc_mean_4
```

```

feature_set['mfcc_std_4'] = mfcc_std_4
feature_set['mfcc_mean_5'] = mfcc_mean_5
feature_set['mfcc_std_5'] = mfcc_std_5
feature_set['rmse_mean'] = rmse_mean # rmse
feature_set['rmse_std'] = rmse_std
feature_set['centroid_mean'] = centroid_mean # centroid
feature_set['centroid_std'] = centroid_std
feature_set['contrast_mean'] = contrast_mean # contrast
feature_set['contrast_std'] = contrast_std
feature_set['flatness_mean'] = flatness_mean # flatness
feature_set['flatness_std'] = flatness_std
feature_set['rolloff_mean'] = rolloff_mean # rolloff
feature_set['rolloff_std'] = rolloff_std
feature_set['zcr_mean'] = zcr_mean # zero crossing rate
feature_set['zcr_std'] = zcr_std

```

Converter para arquivo xlsx

```
feature_set.to_csv('Descritores.xlsx')
```

Chamar função

```
extrair_descritores('local dos arquivos .mp3')
```

APÊNDICE D - ESTATÍSTICAS DESCRITIVAS DA BASE DE DADOS

Descritor	Média	Desvio Padrão	Mínimo	Máximo
<i>Tempo</i>	120,98	29,71	0,00	215,33
<i>Beats</i> (soma)	36166,50	9671,61	0,00	63892,00
<i>Pitch-Shift</i> (média)	0,00	0,00	0,00	0,00
<i>Pitch-Shift</i> (Desvio Padrão)	0,09	0,05	0,00	0,23
<i>Harmonic</i> (Média)	0,00	0,00	-0,01	0,00
<i>Harmonic</i> (Desvio Padrão)	0,10	0,05	0,00	0,26
MFCC_1 (Média)	-4,18	11,54	-61,01	16,87
MFCC_1 (Desvio Padrão)	70,53	33,55	11,11	210,63
MFCC_2 (Média)	-4,85	11,78	-61,03	18,13
MFCC_2 (Desvio Padrão)	71,43	34,33	11,74	210,47
MFCC_3 (Média)	-6,50	12,39	-61,01	17,38
MFCC_3 (Desvio Padrão)	73,03	35,21	11,04	210,31
MFCC_4 (Média)	-6,55	12,36	-61,01	17,18
MFCC_4 (Desvio Padrão)	72,88	35,28	11,52	210,36
MFCC_5 (Média)	-6,50	12,31	-61,02	18,25
MFCC_5 (Desvio Padrão)	72,95	35,22	11,67	210,26
RMS (Média)	0,12	0,07	0,00	0,33
RMS (Desvio Padrão)	0,04	0,02	0,00	0,16
<i>Spectral centroid</i> (Média)	1985,70	650,82	355,41	4263,45
<i>Spectral centroid</i> (Desvio Padrão)	714,57	298,66	51,99	3471,11
<i>Spectral contrast</i> (Média)	21,45	1,61	15,20	26,75
<i>Spectral contrast</i> (Desvio Padrão)	7,84	1,49	3,98	11,50
<i>Spectral flatness</i> (Média)	0,02	0,02	0,00	0,13
<i>Spectral flatness</i> (Desvio Padrão)	0,02	0,01	0,00	0,10
<i>Spectral rolloff</i> (Média)	4099,50	1437,35	325,49	7792,29
<i>Spectral rolloff</i> (Desvio Padrão)	1519,07	563,19	64,91	3872,77
ZCR (Média)	0,09	0,04	0,01	0,38
ZCR (Desvio Padrão)	0,05	0,03	0,00	0,35

APÊNDICE E - CONJUNTOS DE ATRIBUTOS SELECIONADOS

Emoções	Atributos selecionados	Algoritmo de busca	Taxa de acerto (%)
Raiva, Medo, Felicidade, Tristeza e Surpresa	<i>Pitch_mean; Constrast_mean; Constrast_std e ZCR_mean</i>	<i>Best First</i>	37,71%
Raiva, Medo, Felicidade e Tristeza	<i>Pitch_mean; Constrast_mean; Constrast_std; ZCR_mean e ZCR_std</i>	<i>Genetic Search</i>	39,38%
Raiva, Medo e Felicidade	<i>Tempo; Pitch_mean; Harmonic_std; Centroid_std; Constrast_mean; Flatness_mean e ZCR_mean</i>	<i>Genetic Search</i>	40,83%
Raiva, Medo e Tristeza	<i>Pitch_mean; Constrast_mean; Constrast_std e ZCR_mean</i>	<i>Best First</i>	51,67%
Raiva, Felicidade e Tristeza	<i>Pitch_mean; Constrast_mean; Constrast_std e ZCR_mean</i>	<i>Best First</i>	62,50%
Medo, Felicidade e Tristeza	<i>Constrast_mean; Constrast_std e ZCR_mean</i>	<i>Best First</i>	45,00%
Raiva e Medo	<i>Pitch_mean; Harmonic_mean; Constrast_mean; Constrast_std; Flatness_std e ZCR_std</i>	<i>Best First Genetic Search</i>	67,50%
Raiva e Felicidade	<i>Tempo; Pitch_mean; Constrast_mean; Constrast_std; ZCR_mean e ZCR_std</i>	<i>Genetic Search</i>	62,50%
Raiva e Tristeza	<i>Pitch_mean; Constrast_mean; Constrast_std e ZCR_mean</i>	<i>Best First</i>	85,00%
Medo e Felicidade	<i>Tempo; Pitch_mean; MFCC_std_5; Flatness_std e Rolloff_mean</i>	<i>Genetic Search</i>	52,50%
Medo e Tristeza	<i>Constrast_mean; Constrast_std e ZCR_mean</i>	<i>Best First</i>	67,50%
Felicidade e Tristeza	<i>Harmonic_mean; Harmonic_std; MFCC_std_5; Centroid_mean; Constrast_mean; Constrast_std e ZCR_mean</i>	<i>Best First</i>	70,00%

Fonte: Elaborado pelo Autor (2019).

APÊNDICE F – TAXAS DE ACERTO E CENÁRIOS PARA CINCO EMOÇÕES



Treino (Cinco Emoções)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbell(2)	gbell(3)	gbell(4)	gauss(2)	gauss(3)	gauss(4)
50	28,25%	32,10%	34,24%	25,96%	29,81%	29,53%	30,24%	30,53%	38,37%	28,45%	31,95%	38,09%
100	27,96%	32,10%	34,24%	25,96%	29,81%	29,53%	30,10%	30,53%	37,66%	28,53%	31,95%	38,09%
200	27,96%	32,10%	34,24%	25,96%	29,81%	29,53%	30,10%	30,53%	37,66%	28,53%	31,95%	38,09%



Teste (Cinco Emoções)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbell(2)	gbell(3)	gbell(4)	gauss(2)	gauss(3)	gauss(4)
50	24,43%	24,43%	26,70%	20,45%	24,43%	21,02%	24,43%	22,16%	22,16%	22,73%	22,16%	25,57%
100	24,43%	24,43%	26,70%	20,45%	24,43%	21,02%	23,86%	22,16%	21,59%	23,30%	22,16%	25,57%
200	24,43%	24,43%	26,70%	20,45%	24,43%	21,02%	23,86%	22,16%	21,59%	23,30%	22,16%	25,57%

Treino (Cinco Emoções)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbell(2)	gbell(3)	gbell(4)	gauss(2)	gauss(3)	gauss(4)
50	23,97%	23,97%	23,97%	23,97%	23,97%	23,97%	23,97%	23,97%	23,97%	23,97%	23,97%	23,97%
100	23,97%	23,97%	23,97%	23,97%	21,26%	-	23,97%	21,54%	21,54%	23,97%	21,40%	23,97%
200	23,68%	27,67%	-	26,25%	-	-	27,10%	24,68%	27,25%	23,10%	24,11%	21,68%

Teste (Cinco Emoções)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbell(2)	gbell(3)	gbell(4)	gauss(2)	gauss(3)	gauss(4)
50	18,18%	18,18%	18,18%	18,18%	18,18%	18,18%	18,18%	18,18%	18,18%	18,18%	18,18%	18,18%
100	18,18%	18,18%	18,18%	18,18%	25,57%	-	18,18%	25,57%	25,57%	18,18%	25,57%	18,18%
200	17,61%	21,59%	-	21,60%	-	-	22,72%	18,18%	23,86%	17,54%	19,32%	25,57%

APÊNDICE G - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA CINCO EMOÇÕES









APÊNDICE H – TAXAS DE ACERTO E CENÁRIOS PARA QUATRO EMOÇÕES


Treino (Quatro Emoções)					Teste (Quatro Emoções)				
Híbrido	0.50	0.45	0.40	0.35	Híbrido	0.50	0.45	0.40	0.35
50	33,80%	32,71%	32,71%	32,71%	50	26,09%	22,36%	22,36%	28,57%
100	33,80%	34,74%	32,71%	32,71%	100	26,09%	23,60%	22,36%	28,57%
200	33,80%	31,46%	32,71%	32,71%	200	26,09%	24,84%	22,36%	28,57%

Treino (Quatro Emoções)					Teste (Quatro Emoções)				
Backpropagation	0.50	0.45	0.40	0.35	Backpropagation	0.50	0.45	0.40	0.35
50	29,89%	30,83%	32,71%	31,77%	50	22,98%	23,60%	24,22%	23,60%
100	30,05%	30,36,%	32,71%	32,08%	100	22,98%	24,22%	24,22%	21,74%
200	30,05%	30,20%	33,02%	32,08%	200	22,98%	26,09%	22,98%	20,50%

APÊNDICE I - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA QUATRO EMOÇÕES











APÊNDICE J – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES (RAIVA; MEDO E FELICIDADE)



Treino (Raiva; Medo e Felicidade)					Teste (Raiva; Medo e Felicidade)				
Híbrido	0.50	0.45	0.40	0.35	Híbrido	0.50	0.45	0.40	0.35
50	42,29%	46,46%	42,08%	56,25%	50	39,17%	36,67%	35,00%	37,50%
100	42,29%	45,83%	42,50%	56,25%	100	39,17%	36,67%	33,33%	37,50%
200	42,29%	46,25%	42,08%	56,25%	200	39,17%	35,83%	35,00%	37,50%

Treino (Raiva; Medo e Felicidade)					Teste (Raiva; Medo e Felicidade)				
Backpropagation	0.50	0.45	0.40	0.35	Backpropagation	0.50	0.45	0.40	0.35
50	38,13%	41,88%	42,92%	47,50%	50	38,33%	37,50%	34,17%	34,17%
100	39,38%	42,50%	43,45%	50,83%	100	35,83%	38,33%	36,67%	35,00%
200	40,42%	43,96%	42,92%	53,54%	200	36,67%	40,00%	36,67%	34,17%

APÊNDICE K - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS EMOÇÕES (RAIVA; MEDO E FELICIDADE)







APÊNDICE L – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES (RAIVA; MEDO E TRISTEZA)



Treino (Raiva; Medo e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gble(2)	gble(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	50,21%	56,25%	57,92%	57,92%	52,71%	53,13%	51,46%	56,67%	61,88%	51,04%	57,08%	62,08%
100	50,63%	56,25%	57,92%	57,92%	52,71%	53,13%	51,46%	56,67%	61,88%	51,25%	57,08%	62,08%
200	50,42%	56,25%	57,92%	57,92%	52,71%	53,13%	51,46%	56,67%	61,88%	51,25%	57,08%	62,08%



Teste (Raiva; Medo e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	50,83%	55,00%	50,00%	50,00%	50,83%	51,67%	51,57%	56,67%	49,17%	53,33%	56,67%	45,83%
100	50,83%	55,00%	50,00%	50,00%	50,83%	51,67%	53,33%	57,50%	49,17%	54,17%	56,67%	45,83%
200	50,83%	55,00%	50,00%	50,00%	50,83%	51,67%	53,33%	57,50%	49,17%	54,17%	56,67%	45,83%

Treino (Raiva; Medo e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	34,17%	39,79%	39,58%	41,25%	38,75%	43,33%	41,88%	37,71%	38,75%	40,63%	39,58%	39,79%
100	48,13%	47,08%	48,54%	48,13%	40,00%	-	45,42%	47,08%	40,00%	46,04%	45,42%	41,25%
200	48,13%	48,33%	-	51,46%	-	-	47,50%	48,50%	40,83%	46,88%	47,29%	47,08%

Teste (Raiva; Medo e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	31,67%	40,83%	40,83%	44,17%	40,83%	40,83%	45,00%	38,33%	36,67%	44,17%	40,00%	40,00%
100	50,83%	53,33%	49,17%	50,00%	45,00%	-	46,67%	50,00%	41,67%	47,50%	47,50%	43,33%
200	50,00%	54,17%	-	50,83%	-	-	50,00%	53,33%	41,67%	49,17%	48,33%	46,67%

APÊNDICE M - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS EMOÇÕES (RAIVA; MEDO E TRISTEZA)





APÊNDICE N – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES (RAIVA; FELICIDADE E TRISTEZA)



Treino (Raiva; Felicidade e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gble(2)	gble(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	57,50%	61,46%	68,13%	59,17%	55,83%	58,75%	57,50%	62,29%	67,50%	57,71%	61,88%	68,13%
100	57,50%	61,46%	68,13%	59,17%	55,83%	58,75%	57,50%	63,33%	67,50%	57,92%	61,88%	68,13%
200	57,50%	61,46%	68,13%	59,17%	55,83%	58,75%	57,50%	63,33%	67,50%	57,92%	61,88%	68,13%



Treino (Raiva; Felicidade e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	64,17%	61,67%	63,33%	63,33%	53,33%	59,17%	63,33%	61,67%	63,33%	64,14%	63,88%	65,83%
100	64,17%	61,67%	63,33%	63,33%	53,33%	59,17%	63,33%	61,67%	63,33%	64,17%	63,33%	65,83%
200	64,17%	61,67%	63,33%	63,33%	53,33%	59,17%	63,33%	61,67%	63,33%	64,17%	63,33%	65,83%

Treino (Raiva; Felicidade e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	33,96%	43,54%	39,38%	41,88%	42,71%	41,46%	43,96%	41,04%	42,50%	45,63%	42,50%	42,50%
100	56,25%	57,08%	55,83%	56,46%	45,63%	47,92%	52,92%	51,67%	43,33%	53,13%	53,13%	54,58%
200	56,88%	55,21%	57,71%	56,67%	46,04%	-	55,42%	54,38%	57,71%	55,00%	53,96%	54,38%

Teste (Raiva; Felicidade e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	30,83%	45,00%	39,17%	43,33%	43,33%	35,83%	41,87%	40,83%	39,17%	43,33%	42,50%	43,33%
100	58,33%	58,33%	60,00%	60,83%	46,67%	44,17%	59,17%	58,33%	44,17%	58,33%	59,17%	61,67%
200	61,67%	56,67%	56,67%	59,17%	47,50%	-	58,33%	60,83%	60,83%	60,00%	60,00%	59,17%

APÊNDICE O - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS EMOÇÕES (RAIVA; FELICIDADE E TRISTEZA)





APÊNDICE P – TAXAS DE ACERTO E CENÁRIOS PARA TRÊS EMOÇÕES (MEDO; FELICIDADE E TRISTEZA)



Treino (Medo; Felicidade e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gble(2)	gble(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	38,75%	41,46%	43,33%	39,79%	41,88%	40,63%	40,21%	44,17%	47,08%	40,00%	43,13%	45,83%
100	38,96%	41,46%	43,33%	40,00%	41,88%	40,63%	40,63%	44,17%	47,08%	40,63%	43,54%	45,83%
200	38,96%	41,46%	43,33%	40,00%	41,88%	40,63%	40,63%	44,17%	47,08%	40,63%	43,54%	45,83%


Teste (Medo; Felicidade e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gble(2)	gble(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	38,33%	40,00%	39,17%	42,50%	41,67%	38,33%	43,33%	43,33%	45,00%	40,83%	40,00%	44,17%
100	38,33%	40,00%	39,17%	42,50%	41,67%	38,33%	44,17%	43,33%	45,00%	44,17%	40,83%	44,17%
200	38,33%	40,00%	39,17%	42,50%	41,67%	38,33%	44,17%	43,33%	45,00%	44,17%	40,83%	44,17%

Treino (Medo; Felicidade e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	30,42, %	35,83%	31,67%	35,21%	35,00%	28,54%	35,21%	35,63%	35,42%	35,00%	34,79%	35,42%
100	36,88%	35,42%	39,38%	36,46%	36,04%	37,71%	36,46%	35,42%	35,63%	36,04%	35,42%	36,04%
200	38,13%	35,00%	-	41,88%	35,83%	41,04%	38,96%	37,50%	36,67%	36,25%	36,25%	35,21%

Teste (Medo; Felicidade e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	24,17%	38,33%	26,67%	40,00%	34,17%	20,83%	34,17%	35,83%	34,17%	36,67%	35,83%	35,00%
100	37,50%	37,50%	40,00%	36,67%	35,00%	39,17%	35,83%	35,00%	35,83%	37,50%	35,83%	35,83%
200	39,17%	36,67%	-	45,83%	36,67%	41,67%	40,83%	38,33%	35,83%	37,50%	39,17%	35,00%

APÊNDICE Q - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA TRÊS EMOÇÕES (MEDO; FELICIDADE E TRISTEZA)









APÊNDICE R – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES (RAIVA E MEDO)



Treino (Raiva e Medo)					Teste (Raiva e Medo)				
Híbrido	0.50	0.45	0.40	0.35	Híbrido	0.50	0.45	0.40	0.35
50	73,13%	74,06%	74,69%	78,75%	50	72,50%	68,75%	66,25%	66,25%
100	73,13%	74,06%	74,69%	78,75%	100	72,50%	68,75%	66,25%	66,25%
200	73,13%	74,06%	74,69%	78,75%	200	72,50%	68,75%	66,25%	66,25%

Treino (Raiva e Medo)					Teste (Raiva e Medo)				
Backpropagation	0.50	0.45	0.40	0.35	Backpropagation	0.50	0.45	0.40	0.35
50	67,19%	74,06%	74,69%	77,19%	50	51,25%	66,25%	66,25%	67,50%
100	65,63%	74,69%	75,63%	77,19%	100	53,75%	66,25%	66,25%	67,50%
200	65,31%	73,44%	76,56%	77,19%	200	52,50%	67,50%	68,75%	67,50%

APÊNDICE S - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS EMOÇÕES (RAIVA E MEDO)











APÊNDICE T – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES (RAIVA E FELICIDADE)



Treino (Raiva e Felicidade)					Teste (Raiva e Felicidade)				
Híbrido	0.50	0.45	0.40	0.35	Híbrido	0.50	0.45	0.40	0.35
50	80,00%	81,56%	81,88%	85,94%	50	63,75%	65,00%	70,00%	70,00%
100	80,00%	81,56%	81,88%	85,94%	100	63,75%	65,00%	70,00%	70,00%
200	80,00%	81,56%	81,88%	85,94%	200	63,75%	65,00%	70,00%	70,00%

Treino (Raiva e Felicidade)					Teste (Raiva e Felicidade)				
Backpropagation	0.50	0.45	0.40	0.35	Backpropagation	0.50	0.45	0.40	0.35
50	74,06%	79,06%	75,94%	77,81%	50	70,00%	65,00%	63,75%	71,25%
100	73,44%	80,00%	79,06%	78,75%	100	70,00%	66,25%	66,25%	67,50%
200	75,94%	80,94%	77,19%	79,69%	200	70,00%	71,25%	62,50%	66,25%

APÊNDICE U - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS EMOÇÕES (RAIVA E FELICIDADE)







APÊNDICE V – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES (RAIVA E TRISTEZA)



Treino (Raiva e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	84,06%	84,38%	90,63%	83,44%	83,44%	84,69%	83,44%	86,56%	91,88%	83,44%	85,94%	90,63%
100	83,75%	84,38%	90,63%	83,44%	83,44%	84,69%	83,44%	85,94%	91,88%	83,44%	85,94%	90,63%
200	83,75%	84,38%	90,63%	83,44%	83,44%	84,69%	83,44%	85,94%	91,88%	83,44%	85,94%	90,63%


Teste (Raiva e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	87,50%	82,50%	82,50%	86,25%	81,25%	85,00%	86,25%	85,00%	75,00%	86,25%	85,00%	77,50%
100	86,25%	82,50%	82,50%	86,25%	81,25%	85,00%	86,25%	83,75%	75,00%	86,25%	85,00%	77,50%
200	86,25%	82,50%	82,50%	86,25%	81,25%	85,00%	86,25%	83,75%	75,00%	86,25%	85,00%	77,50%

Treino (Raiva e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	75,31%	67,81%	76,25%	79,69%	74,06%	77,50%	78,13%	77,81%	76,88%	77,81%	78,44%	78,44%
100	81,56%	81,56%	78,44%	82,19%	81,88%	-	80,63%	80,63%	79,06%	80,94%	80,00%	79,69%
200	83,13%	84,04%	-	81,88%	81,56%	-	82,50%	81,88%	78,75%	80,94%	80,63%	80,31%

Teste (Raiva e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	80,00%	73,75%	78,75%	83,75%	71,25%	78,75%	83,75%	83,75%	77,50%	82,50%	82,50%	85,00%
100	85,00%	78,75%	82,50%	85,00%	77,50%	-	82,50%	80,00%	78,75%	80,00%	82,50%	80,00%
200	87,50%	80,00%	-	88,75%	81,25%	-	85,00%	81,25%	81,25%	85,00%	80,00%	80,00%

APÊNDICE W - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS EMOÇÕES (RAIVA E TRISTEZA)









APÊNDICE X – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES (MEDO E FELICIDADE)


Treino (Medo e Felicidade)					Teste (Medo e Felicidade)				
Híbrido	0.50	0.45	0.40	0.35	Híbrido	0.50	0.45	0.40	0.35
50	72,81%	70,63%	76,25%	79,69%	50	51,25%	55,00%	55,00%	47,50%
100	72,81%	70,63%	76,25%	79,69%	100	51,25%	55,00%	55,00%	47,50%
200	72,81%	70,63%	76,25%	79,69%	200	51,25%	55,00%	55,00%	47,50%

Treino (Medo e Felicidade)					Teste (Medo e Felicidade)				
Backpropagation	0.50	0.45	0.40	0.35	Backpropagation	0.50	0.45	0.40	0.35
50	69,06%	69,69%	73,44%	75,63%	50	55,00%	57,50%	53,75%	55,00%
100	70,94%	70,63%	74,69%	77,81%	100	56,25%	57,50%	55,00%	56,25%
200	71,56%	70,94%	74,69%	78,13%	200	57,50%	56,25%	57,50%	55,00%

APÊNDICE Y - FUNÇÕES DE PERTINÊNCIA PARA DUAS EMOÇÕES (MEDO E FELICIDADE)







APÊNDICE Z – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES (MEDO E TRISTEZA)



Treino (Medo e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	65,31%	66,56%	67,81%	65,00%	64,06%	66,56%	65,00%	67,81%	70,31%	62,81%	67,19%	71,25%
100	65,00%	65,94%	67,81%	65,00%	64,06%	66,56%	66,88%	67,81%	70,31%	64,38%	67,19%	71,25%
200	65,00%	65,94%	67,81%	65,00%	64,06%	66,56%	66,88%	67,81%	70,31%	64,38%	67,19%	71,25%


Teste (Medo e Tristeza)												
Híbrido	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gble(2)	gble(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	73,75%	66,25%	70,00%	67,50%	70,00%	67,50%	75,00%	67,50%	62,50%	72,50%	68,75%	60,00%
100	76,25%	68,75%	70,00%	67,50%	70,00%	67,50%	66,25%	67,50%	62,50%	72,50%	68,75%	60,00%
200	76,25%	68,75%	70,00%	67,50%	70,00%	67,50%	66,25%	67,50%	62,50%	72,50%	68,75%	60,00%

Treino (Medo e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gbel(2)	gbel(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	51,88%	59,38%	54,69%	59,69%	60,00%	59,69%	59,06%	65,63%	61,88%	57,81%	65,31%	63,44%
100	65,63%	65,63%	65,00%	57,81%	63,44%	62,19%	63,44%	65,00%	64,69%	62,50%	65,31%	65,94%
200	65,63%	65,31%	65,63%	65,00%	64,69%	63,13%	62,81%	65,94%	65,63%	63,75%	63,75%	66,56%

Teste (Medo e Tristeza)												
Backpropagation	tri(2)	tri(3)	tri(4)	trap(2)	trap(3)	trap(4)	gble(2)	gble(3)	gble(4)	gauss(2)	gauss(3)	gauss(4)
50	42,50%	60,00%	51,25%	61,25%	62,50%	61,25%	62,50%	72,50%	66,25%	61,25%	72,50%	73,75%
100	75,00%	70,00%	67,50%	71,25%	73,75%	66,25%	70,00%	70,00%	70,00%	71,25%	67,50%	70,00%
200	70,00%	70,00%	67,50%	72,50%	71,25%	66,25%	70,00%	71,25%	70,00%	71,25%	72,50%	70,00%

APÊNDICE AA - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS EMOÇÕES (MEDO E TRISTEZA)





APÊNDICE BB – TAXAS DE ACERTO E CENÁRIOS PARA DUAS EMOÇÕES (FELICIDADE E TRISTEZA)

Treino (Felicidade e Tristeza)					Teste (Felicidade e Tristeza)				
Híbrido	0.50	0.45	0.40	0.35	Híbrido	0.50	0.45	0.40	0.35
50	84,06%	90,63%	93,13%	95,00%	50	75,00%	83,75%	77,50%	73,75%
100	84,06%	91,56%	95,63%	95,94%	100	75,00%	82,50%	81,25%	73,75%
200	84,06%	91,56%	95,31%	95,94%	200	75,00%	82,50%	81,25%	73,75%

Treino (Felicidade e Tristeza)					Teste (Felicidade e Tristeza)				
Backpropagation	0.50	0.45	0.40	0.35	Backpropagation	0.50	0.45	0.40	0.35
50	82,50%	84,38%	86,25%	87,19%	50	73,75%	78,75%	75,00%	80,00%
100	82,50%	83,75%	86,25%	87,81%	100	73,75%	81,25%	76,25%	80,00%
200	82,81%	85,00%	87,50%	89,06%	200	73,75%	80,00%	77,50%	80,00%

APÊNDICE CC - FUNÇÕES DE PERTINÊNCIA OBTIDAS PARA DUAS EMOÇÕES (FELICIDADE E TRISTEZA)

